

**Entwicklung einer übertragbaren, synergistischen Methode zur  
Kartierung von Biotoptypen anhand von hochauflösenden optischen  
und Radar-basierten Daten**

**Dissertation**

zur Erlangung des akademischen Grades *doctor rerum naturalium*

(Dr. rer. nat.)

vorgelegt dem Rat der Chemisch-Geowissenschaftlichen Fakultät der  
Friedrich-Schiller-Universität Jena

von M. Sc. Marcus Bindel

geboren am 09. Juli 1983 in Eisenach

Gutachter:

1. Prof. Dr. rer. nat. Christiane Schmullius (Friedrich-Schiller-Universität Jena)
2. PD Dr. rer. nat. habil. Sören Hese (Friedrich-Schiller-Universität Jena)

Tag der Verteidigung:  
19.12.2019

*Eine Vision ohne Aktion ist ein Taetraum.  
Eine Aktion ohne Vision ist ein Alptraum.*

Japanisches Sprichwort

## Danksagung

Mein besonderer Dank gilt Prof. Dr. Christiane Schmullius und PD Dr. Sören Hese für die ausgezeichnete Ausbildung am Lehrstuhl für Fernerkundung an der Friedrich-Schiller-Universität Jena und die ungebrochene Unterstützung, trotz einer langen Pause, bei der Fertigstellung dieser Arbeit.

Darüber hinaus gilt mein Dank Dr. Christian Berger für die fachlichen und privaten Gespräche während meiner Zeit in Jena sowie das Korrekturlesen in der finalen Phase der Dissertation, Dr. Richard Fuchs für die hilfreichen Anmerkungen in der finalen Phase der Dissertation, Dr. Knut Hartmann für die konstruktiven Gespräche im Bereich der Fernerkundung und Geoinformatik und Dr. Thomas Heege für die sehr angenehme Arbeitsatmosphäre bei der EOMAP GmbH & Co. KG und die Erlaubnis zur Nutzung der Software und Hardware für die Datenanalyse im Zuge dieser Arbeit.

Nicht zuletzt gilt mein besonderer Dank meiner Frau Julia und meinen beiden Kindern für ihre Geduld und ihre Unterstützung während des gesamten Arbeitszeitraumes.



## Kurzfassung

Um den Anforderungen der nationalen und internationalen Naturschutzrichtlinien, z.B. die Kartierung der Lebensraumtypen des Anhangs I der Flora-Fauna-Habitat Richtlinie (FFH-Richtlinie) zu entsprechen, ist die Entwicklung detaillierter Biotoptypen-, Landbedeckungs- und Landnutzungskartierungen von entscheidender Bedeutung. Hierbei bieten sich hochaufgelöste Fernerkundungsdaten und weitere verfügbare Geoinformationen, wie LiDAR-Befliegungen und Vektorinformationen als Informationsgrundlage an. Die synergistische Verwendung der genannten Daten birgt großes Potenzial den nationalen und internationalen Anforderungen nach detaillierten und flächenhaften Informationen der planungsrelevanten Parameter, wie der Biotoptypenverteilung beziehungsweise Landbedeckung- und Landnutzung, teilweise oder ganz zu entsprechen. Allerdings fehlen zum jetzigen Zeitpunkt geeignete Methoden, um aus der Vielzahl der vorhandenen Geoinformationen die, für die Erfassung der planungsrelevanten Parameter relevanten, Merkmale zu extrahieren und in verwendbare Karten zu überführen. Die vorliegende Arbeit hat zum Ziel eine solche Methode zu entwickeln.

Das übergeordnete Ziel dieser Arbeit war es zu evaluieren, in welchem Umfang die synergistische Verwendung von modernen Erdbeobachtungsdaten und -methoden zur Kartierung von Biotoptyp- und Landnutzungsinformationen beitragen kann. Anhand einer umfangreichen Literaturrecherche wurden die traditionellen Methoden der Biotoptypenkartierung und der Stand der Forschung im Bereich der Verwendung von Fernerkundungsinformationen für die Biotoptypenkartierung analysiert und Forschungsdefizite aufgezeigt, sowie Ansatzpunkte für eine Weiterentwicklung definiert. Hieraus ergaben sich die folgenden vier übergeordneten Forschungs- beziehungsweise Arbeitsschwerpunkte, welche im Verlauf der Arbeit noch weiter unterteilt wurden:

1. Die Analyse und Extraktion von potenziellen Informationen (Merkmalen) aus den vorliegenden Geoinformationen und die anschließende Reduktion der potenziellen Merkmale auf die relevanten Merkmale für die Kartierung der Biotoptyp- und Landnutzungsinformationen.
2. Die Entwicklung eines Klassifikationsansatzes für die Erfassung der Biotoptypen- und Landnutzungsinformationen anhand eines Entwicklungsdatensatzes.
3. Die Evaluation der Robustheit der Methode mittels Übertragung auf zwei weitere Datensätze.
4. Die Evaluation der Synergie der zugrundeliegenden Geoinformationen.

Als Basis dienen Geoinformationen für zwei Untersuchungsgebiete, Rostock und Groitzsch, welche sich beide in Deutschland befinden. Die Geoinformationen sind unterteilt in Raster- und Vektordaten. Die Rasterdaten umfassen die Satellitendaten, welche sich in multispektrale RapidEye- und Sentinel-2-Daten und Radar-basierten TerraSAR-X- und Sentinel-1-Daten unterteilen, und auf LiDAR-Daten beruhende Objekthöhen. Die Vektordaten umfassen die als Referenzdaten dienenden Biotop- und Landnutzungskartierungen der Länder und OpenStreetMap-Daten. Aus den vorhandenen Daten wurden drei Testdatensätze definiert:

1. Entwicklungsdatensatz Rostock (RapidEye- und TerraSAR-X-Daten aus 2009 und 2010),
2. Übertragbarkeitsdatensatz Groitzsch (RapidEye- und TerraSAR-X-Daten aus 2009 und 2010),
3. Übertragbarkeitsdatensatz Rostock (Sentinel-1- und Sentinel-2-Daten aus dem Jahr 2017).

Der erste Forschungsschwerpunkt zielt darauf ab, den in der Literaturrecherche offensichtlich geworden Mangel, der Analyse aller potenziell erzeugbaren Informationen (Merkmale) und die anschließende Reduktion auf nur die für die Erfassung der jeweiligen Biotoptypen relevanten Merkmale, zu beheben. Dieser Schritt der Merkmalsauswahl wurde in Merkmalsranking und Merkmalsreduktion unterteilt. Im Bereich des Merkmalsrankings wurden verschiedene Methoden evaluiert und die, für die vorliegenden Daten und Klassen, geeignetste Methode, die *Support Vector*

*Machines*, ausgewählt. Anschließend wurden die benötigten Parameter der *Support Vector Machines* evaluiert und optimiert. Als Methode für die Merkmalsreduktion und als grundlegende Methode für die Klassifikation wurde anhand der Literaturrecherche der *Random Forest* selektiert. Die Gründe für die Auswahl des gleichen Ansatzes für die Merkmalsreduktion und die Klassifikation liegen in der angestrebten Konsistenz und der Nutzung der in der Literatur aufgezeigten Vorteile des *Random Forest* begründet. Die Ergebnisse der Merkmalsauswahl zeigten, dass es bei gleichbleibender oder höherer erzielter Genauigkeit möglich war, die verwendeten Merkmale je Datensatz um 98 % - 99,6 % zu reduzieren und somit massiv den benötigten Speicherplatz und die benötigte Rechenleistung zu verringern.

Die zweite Forschungsfrage zielte darauf ab, die selektierte Klassifikationsmethode (*Random Forest*) in einen robusten und übertragbaren Klassifikationsansatz einzubetten. Dies geschah auf Basis des Entwicklungsdatensatzes Rostock. Anwendung fand ein auf einer Segmentierung beruhender objekt-basierter Ansatz mit mehreren (sechs) erzeugten Objektgrößen. Die Verwendung von unterschiedlichen Objektgrößen basiert auf der Analyse der Segmentierungen und dem Ergebnis, dass eine feinere Segmentierung sich besser eignet um kleine Objekte, wie Häuser oder kleine Wasserflächen, und eine gröbere Segmentierung sich besser eignet um große, homogene Bereiche, wie landwirtschaftliche Nutzflächen, zu erfassen. Die Klassifikation wurde klassenweise durchgeführt, um zu evaluieren an welcher Stelle sich Klassen überlagern beziehungsweise an welcher Stelle die Klassifikation eindeutig ist. Dies resultierte in einem Häufigkeitsdatensatz, welcher pixelweise anzeigt, ob eine Klassifikation eindeutig oder zwei- beziehungsweise mehrdeutig ist. Die Klassen werden hierbei unterteilt in auf *weichen* Merkmalen oder auf *harten* Merkmalen beruhend. Die weichen Merkmale sind die aus der Merkmalsauswahl automatisch selektierten Merkmale je Klasse. Die *harten* Merkmale definieren sich dagegen direkt aus der Klassenbeschreibung. So sind zum Beispiel die Waldklassen durch den Anteil an Laub- beziehungsweise Nadelbaumbeständen definiert. Die *harten* Merkmale umfassen somit relationale und geometrische Merkmale für die Klassenbeschreibung. Abschließend wurden die einzelnen Klassen in ein Klassifikationsergebnis überführt und die Genauigkeit mittels Gesamtgenauigkeit, Kappa-Koeffizienten und F-Maß evaluiert. Für den Entwicklungsdatensatz Rostock konnte eine Gesamtgenauigkeit für die vier Klassen der Hauptgruppe von maximal 96,7 %, für die sieben Klassen der Untergruppe von maximal 95,6 % und maximal 77 % für die 21 Detailklassen erreicht werden.

Die dritte Forschungsfrage zielte darauf ab, die Übertragbarkeit des Klassifikationsansatzes zu überprüfen. Anwendung fanden hierfür der Übertragbarkeitsdatensatz Grotzsch und der Übertragbarkeitsdatensatz Rostock. Die Definitionen für die Klassen basierend auf den *harten* Merkmalen wurden unverändert übernommen, die Definitionen für die Klassen basierend auf den *weichen* Merkmalen wurden automatisch durch die Merkmalsauswahl für jeden Datensatz angepasst. Für den Übertragbarkeitsdatensatz Grotzsch konnte eine Gesamtgenauigkeit für die vier Klassen der Hauptgruppe von maximal 98,1 %, für die sieben Klassen der Untergruppe von maximal 99,1 % und maximal 86,1% für die 17 Detailklassen erreicht werden. Für den Übertragbarkeitsdatensatz Rostock konnte eine Gesamtgenauigkeit von maximal 91,9 % für die vier Klassen der Hauptgruppe, von maximal 95,7 % für die sieben Klassen der Untergruppe und maximal 70,4% für die 20 Detailklassen erreicht werden.

Die vierte Forschungsfrage hatte das Ziel, zu analysieren inwieweit die synergistische Verwendung der unterschiedlichen Datenquellen (multispektrale Satellitendaten, Radar-basierte Satellitendaten und LiDAR-basierte Daten) Einfluss auf die resultierende Genauigkeit der Klassifikation hat. Analysiert wurden die einzelnen Klassen, basierend auf den weichen Merkmalen, anhand des F-Maßes. Die Analyse hat gezeigt, dass einige Klassen nur gering von der Synergie durch einen Anstieg des F-Maßes von 0,92 (nur eine Datenquelle) auf 0,95 (synergistische Verwendung der Datenquellen) profitieren können, es jedoch auch Klassen gibt, welche stark von der Synergie durch einen Anstieg des F-Maßes von 0,4 (nur eine Datenquelle) auf 1 (synergistische Verwendung der Datenquellen) profitieren.

Generell hat sich gezeigt, dass die synergistische Verwendung von mindestens zwei Datenquellen mindestens die gleiche Genauigkeit, in den meisten Fällen eine höhere Genauigkeit, erzielt, als die Verwendung von nur einer Datenquelle.

Somit konnte gezeigt werden, dass das Ziel der Entwicklung einer übertragbaren, synergistischen Methode zur Kartierung von Biototypen anhand von hochauflösenden optischen und Radar-basierten Daten erreicht werden konnte. Die entstandenen Karten können als Hilfe für die Entscheidungsfindung im Bereich der Anforderungen der nationalen und internationalen Naturschutzrichtlinien dienen. Die gezeigten Ergebnisse im Bereich der Übertragbarkeit lassen darauf hoffen, dass die entwickelte Methode und die daraus entstehenden Ergebnisse auch in anderen Ökoregionen einsetzbar sind.

Schlüsselwörter – Fernerkundung, Biototypen, Landbedeckung, Synergie, Merkmalsauswahl, maschinelles Lernen, Klassifikation, Übertragbarkeit, hochaufgelöst, multispektral, objekt-basiert

## Abstract

In order to meet the requirements of national and international nature conservation guidelines, e.g. the mapping of habitat types in Annex I of the Council Directive 92/43/EEC on the Conservation of natural habitats and of wild fauna and flora (Habitats Directive), the development of detailed biotope type, land cover and land use maps is of crucial importance. Here for high-resolution remote sensing data and other available geoinformation, such as LiDAR surveys and vector information, can be used as a basis. The synergistic use of the mentioned data holds great potential to partially or completely meet the national and international requirements for detailed and spatial information on relevant planning parameters, such as biotope type distribution or land cover and land use. At present, however, there is a lack of suitable methods to extract the relevant characteristics from the multitude of available geoinformation and to convert them into usable maps for representing the relevant planning parameters. The aim of this thesis is to develop such a method.

The overall objective of this work was to evaluate the extent to which the synergistic use of modern Earth observation data and Earth observation methods can contribute to the mapping of biotope type and land use information. On the basis of an extensive literature search, the traditional methods of biotope type mapping and the state of research in the field of the use of remote sensing information for biotope type mapping were analysed, research deficits were identified and starting points for further development were defined. This resulted in the following four overarching research and work priorities, which were further subdivided in the course of the work:

1. the analysis and extraction of potential information (features) from the available geodata and the subsequent reduction of the potential features to the relevant features for the mapping of biotope types and land use information.
2. the development of a classification approach for the mapping of biotope types and land use information based on a development data set.
3. the evaluation of the robustness of the method by transferring to two further data sets
4. the evaluation of the synergy of the underlying geoinformation.

Geodata for two study areas, Rostock and Groitzsch, both located in Germany, serve as a basis. The geodata is divided into raster and vector data. The raster data comprise the satellite data, which are divided into multispectral RapidEye and Sentinel-2 data and radar-based TerraSAR-X and Sentinel-1 data, and object heights based on LiDAR data. The vector data include the reference biotope and land use mapping of the countries and OpenStreetMap data. Three test data sets were defined from the existing data:

1. development data set Rostock (RapidEye and TerraSAR-X data from 2009 and 2010),
2. transferability data set for Groitzsch (RapidEye and TerraSAR-X data from 2009 and 2010) and
3. transferability data set Rostock (Sentinel 1 and Sentinel 2 data from 2017).

The first research focus aims to remedy the lack of potentially producible information (features) that has become apparent in literature research and the subsequent reduction to only those features that are relevant for the mapping of the respective biotope types. This step of feature selection was divided into feature ranking and feature reduction. In the area of feature ranking, various methods were evaluated and the most suitable method for the available data and classes, the Support Vector Machines, was selected. Subsequently, the required parameters of the Support Vector Machines were evaluated and optimized. *Random Forest* was selected as the method for feature reduction and as the basic method for classification on the basis of literature research. The reasons for selecting the same method for feature reduction and classification are based on the desired consistency and the use of the advantages of *Random Forest* as described in the literature. The results of the feature selection showed that it was

possible to reduce the used features per data set by 98.0 % - 99.6 % and thus drastically reduce the required storage space and computing power while maintaining or increasing the achieved accuracy.

The second research question aimed to embed the selected classification method (*Random Forest*) in a robust and transferable classification approach. This was done on the basis of the Rostock development data set. An object-based approach based on segmentation with several (six) generated object sizes was applied. The use of different object sizes is based on the analysis of the segmentations and the result that a finer segmentation is more suitable for small objects, such as houses or small water areas, and a coarser segmentation is more suitable for large, homogeneous areas, such as agricultural land. Classification was performed on a class basis to evaluate where classes overlap and where the classification is unique. This resulted in a frequency data set which shows pixel by pixel whether a classification is unique or ambiguous. The classes are subdivided into those based on soft features or those based on hard features. The soft features are the features automatically selected from the feature selection process for each class. The hard features, on the other hand, are defined directly from the class description. For example, the forest classes are defined by the proportion of deciduous or coniferous trees. The hard features thus include relational and geometric features for the class description. Finally, the individual classes were converted into a single classification result and the accuracy was evaluated by means of overall accuracy, kappa coefficients and F-score. For the development data set Rostock, an overall accuracy for the four classes of the main group a maximum of 96.7 % could be achieved, a maximum of 95.6 % for the seven classes of the subgroup and a maximum of 77 % for the 21 detail classes.

The third research question aimed to examine the transferability of the classification approach. The transferability data set Groitzsch and the transferability data set Rostock were used for this purpose. The class definitions for the classes based on the hard features were adopted unchanged, the class definitions for the classes based on the soft features were automatically adapted by the feature selection for each data set. For the transferability data set Groitzsch, an overall accuracy of maximum 98.1 % could be achieved for the four classes of the main group, a maximum of 99.1 % for the seven classes of the subgroup and a maximum of 86.1% for the 17 detail classes. For the transferability data set Rostock an overall accuracy a maximum of 91.9 % could be achieved for the four classes of the main group, a maximum of 95.7 % for the seven classes of the subgroup and a maximum of 70.4 % for the 20 detail classes.

The fourth research question aimed to analyse to what extent the synergistic use of the different data sources (multispectral satellite data, radar-based satellite data and LiDAR-based data) has an influence on the resulting accuracy of the classification. The individual classes were analyzed based on the soft features and the resulting F-score. The analysis has shown that classes can benefit only slightly from the synergy by increasing the F-score from 0.92 (only one data source) to 0.95 (synergistic use of data sources), but there are also classes that benefit strongly from the synergy by increasing the F-score from 0.4 (only one data source) to 1 (synergistic use of data sources). In general, it has been shown that the synergistic use of at least two data sources achieves at least the same accuracy, in most cases a higher accuracy, than the use of only one data source.

Thus, it could be shown that the goal of developing a transferable, synergistic method for mapping biotope types using high-resolution optical and radar-based data could be achieved. The resulting maps can serve as an aid for decision-making in the field of the requirements for national and international nature conservation guidelines. The results shown in the field of transferability give reason to hope that the developed method can also be used in other ecoregions.

Keywords - remote sensing, biotope types, land cover, synergy, feature selection, classification, machine learning, transferability, high-resolution, multispectral, object-based

# Inhaltsverzeichnis

<b>Danksagung.....</b>	<b>IV</b>
<b>Kurzfassung .....</b>	<b>V</b>
<b>Abstract .....</b>	<b>VIII</b>
<b>Inhaltsverzeichnis .....</b>	<b>X</b>
<b>Abbildungsverzeichnis .....</b>	<b>XII</b>
<b>Tabellenverzeichnis.....</b>	<b>XVI</b>
<b>Abkürzungsverzeichnis.....</b>	<b>XVIII</b>
<b>1 Einleitung.....</b>	<b>1</b>
1.1 Motivation .....	1
1.2 Zielstellung und Gliederung .....	2
<b>2 Grundlagen.....</b>	<b>3</b>
2.1 Fernerkundung .....	3
2.2 Klassifikation.....	4
2.3 Biotop, Biotoptyp und Landschaftselemente.....	5
<b>3 Stand der Forschung .....</b>	<b>7</b>
3.1 Traditionelle Methoden der Biotoptypenkartierung .....	8
3.2 Monitoringansätze.....	9
3.3 Klassifikationssysteme und Interpretierschlüssel .....	11
3.3.1 Biotop- und Landnutzungskartierung.....	11
3.3.2 Coordination of information on the environment .....	13
3.3.3 Fauna-Flora-Habitat-Richtlinie .....	13
3.3.4 European Nature Information System .....	14
3.4 Fernerkundung für die Biotoptypenerfassung .....	15
3.4.1 Optische Satellitenbilder.....	15
3.4.2 Color-Infrarot- und Hyperspektrale-Luftbilder .....	19
3.4.3 Aktive Fernerkundung .....	21
3.4.4 Synergistische Methoden .....	23
3.4.5 Fernerkundung für die Landschaftselementkartierung .....	25
3.5 Merkmalsauswahl.....	27
3.5.1 Maße, Kriterien und Methoden .....	27
<b>4 Arbeitsbasis.....</b>	<b>31</b>
4.1 Untersuchungsgebiete .....	31
4.2 Datengrundlage.....	33
4.2.1 RapidEye.....	33
4.2.2 TerraSAR-X.....	34

4.2.3	Sentinel-1 .....	35
4.2.4	Sentinel-2 .....	35
4.2.5	Referenzdaten und thematische Daten .....	36
4.2.6	Datensätze .....	37
4.3	Vorverarbeitung der optischen Satellitendaten .....	38
4.3.1	Geometrische Korrektur .....	38
4.3.2	Atmosphärenkorrektur .....	38
4.4	Vorverarbeitung der SAR-Satellitendaten .....	41
4.5	Klassifikationsziel .....	42
<b>5</b>	<b>Wissensbasis und Methoden.....</b>	<b>48</b>
5.1	Erzeugung der Wissensbasis .....	49
5.1.1	Potenzielle Merkmale .....	49
5.1.2	Merkmalsbeschreibung .....	51
5.1.3	Erwartete Merkmale der Biotoptypen .....	55
5.2	Klassifikationsansatz .....	60
5.2.1	Segmentierung .....	60
5.2.2	Klassifikationsmethode .....	62
5.2.3	Klassifikationsablauf .....	64
5.2.4	Häufigkeitsdatensatz .....	67
5.2.5	Klassenzusammenlegung .....	68
5.2.6	Übertragbarkeit .....	68
5.2.7	Genauigkeitsanalyse .....	68
5.3	Methodik der Merkmalsauswahl .....	70
5.3.1	Merkmalsvorverarbeitung und Merkmalsnormalisierung .....	70
5.3.2	Auswahl der Trennbarkeitsmaße .....	70
5.3.3	Merkmalsranking .....	72
5.3.4	Merkmalsreduktion .....	74
5.4	Synergie .....	75
<b>6</b>	<b>Ergebnisse.....</b>	<b>76</b>
6.1	Merkmalsauswahl .....	76
6.1.1	Entwicklungsdatensatz Rostock .....	76
6.1.2	Übertragbarkeitsdatensatz Groitzsch .....	83
6.1.3	Übertragbarkeitsdatensatz Rostock .....	83
6.2	Segmentierung .....	85
6.3	Klassifikationsergebnisse und Genauigkeitsanalyse .....	89
6.3.1	Entwicklungsdatensatz Rostock .....	89
6.3.2	Übertragbarkeitsdatensatz Groitzsch .....	107
6.3.3	Übertragbarkeitsdatensatz Rostock .....	123
6.4	Synergieeffekte .....	140
<b>7</b>	<b>Zusammenfassung und Diskussion .....</b>	<b>142</b>
<b>8</b>	<b>Literatur.....</b>	<b>154</b>
<b>Anhang</b>	<b>.....</b>	<b>171</b>

# Abbildungsverzeichnis

Abbildung 1: Untersuchungsgebiet Rostock.....	31
Abbildung 2: Untersuchungsgebiet Groitzsch. ....	32
Abbildung 3: RapidEye und TerraSAR-X Abdeckungen für die Untersuchungsgebiete Rostock und Groitzsch für die Jahre 2009 und 2010.....	35
Abbildung 4: Sentinel-1 und Sentinel-2 Abdeckungen für das Untersuchungsgebiet Rostock für das Jahr 2017.....	36
Abbildung 5: Vergleich der Zeitschnitte 1991 (a) und 2003 (b) der BNTK (Mecklenburg-Vorpommern) – gelb, orange und rot entsprechen Grünlandklassen und grün Waldklassen - und einem Echtfarbenausschnitt einer RapidEye Szene von 2009 (c).....	37
Abbildung 6: Klassifikationsziel (Hauptgruppe (blau), Untergruppe (grün) und Detailklassen (orange))..	47
Abbildung 7: Grundlegende Prozesskette zur Schaffung der Wissensbasis und der Klassifikation (verändert nach THEODORIDIS & KOUTROUMBAS, 2009).....	48
Abbildung 8: Trennbarkeit zweier Klassen anhand zweier Merkmale (THEODORIDIS & KOUTROUMBAS, 2009). ....	49
Abbildung 9: Typische Spektren für die Baumarten Espe (a), Eiche (b), Kiefer (c) und Fichte (d) (Quelle: CLARK ET AL., 2007).....	56
Abbildung 10: Typische Spektren für Grünland: 90 % trockenes und 10 % vitales Gras (a), vitales Gras (b) (Quelle: CLARK ET AL., 2007).....	57
Abbildung 11: Typische Spektren für offene Wasserflächen (a) und offenem Boden (b) (Quelle: CLARK ET AL., 2007).....	57
Abbildung 12: Typische Spektren für offene Asphalt (a) und Beton (b) (Quelle: CLARK ET AL., 2007).....	58
Abbildung 13: Aufsummierten Häufigkeiten der lokalen Maxima je <i>Scale Parameter</i> für RapidEye (a) und Sentinel-2 (b).....	61
Abbildung 14: Visualisierung der Klassifikationsgüte unter Verwendung unterschiedlicher Baumtiefen für den RF-Klassifikator.....	63
Abbildung 15: Visualisierung der Klassifikationsgüte und Laufzeit unter Verwendung unterschiedlicher Baumanzahl für den RF-Klassifikator.....	64
Abbildung 16: Klassifikationsablauf für Klassen basierend auf weichen Merkmalen.....	65
Abbildung 17: Klassifikationsablauf für die Landschaftselement- und Waldklassen.....	66
Abbildung 18: Klassifikationsablauf für die Siedlungs- und Infrastrukturklassen basierend auf harten Merkmalen.....	66
Abbildung 19: Merkmalsausprägungen für die Klassen Gewässer (Blau), Laubbaumbestand (Dunkelgrün) und Grünland (Hellgrün) des blauen RapidEye-Kanal (20. August 2009), der VV-Polarisation der TerraSAR-X SM-Aufnahme (27. April 2009) und des ersten Kanals der MNF-Transformation (20. August 2009).....	71
Abbildung 20: Kernelpformance für die Klasse Baumvegetation.....	73
Abbildung 21: F-Maß (y-Achse) je Merkmal (x-Achse) für die Klassen der Hauptgruppe.....	77
Abbildung 22: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl.....	78
Abbildung 23: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern.....	79
Abbildung 24: Verteilung der weichen Merkmale auf die Merkmalskategorien (Entwicklungsgebiet Rostock).....	82



Abbildung 25: Verteilung der weichen Merkmale auf die Merkmalskategorien (Übertragbarkeitsdatensatz Grotzsch).	83
Abbildung 26: Verteilung der weichen Merkmale auf die Merkmalskategorien (Übertragbarkeitsdatensatz Rostock).	84
Abbildung 27: Verteilung der weichen Merkmale auf die Merkmalskategorien inklusive der multi-temporalen Merkmale (Übertragbarkeitsdatensatz Rostock).	84
Abbildung 28: Referenzobjektanzahl je Größenkategorie.	85
Abbildung 29: Evaluation area fit index (AFI)	86
Abbildung 30: Evaluation over merging (OM)	86
Abbildung 31: Evaluation under merging (UM)	87
Abbildung 32: Beispielhafte Darstellung der Segmentierungsebenen, sowie der jeweils pro Referenzobjekt erzeugten Segmente, anhand dreier Objekte.	88
Abbildung 33: Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).	90
Abbildung 34: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Hauptgruppe.	91
Abbildung 35: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	93
Abbildung 36: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	94
Abbildung 37: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Hauptgruppe.	95
Abbildung 38: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	97
Abbildung 39: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	98
Abbildung 40: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Untergruppe.	99
Abbildung 41: Konfusionsmatrizen für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).	100
Abbildung 42: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Untergruppe.	101
Abbildung 43: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Detailklassen.	102
Abbildung 44: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	104
Abbildung 45: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	105
Abbildung 46: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Detailklassen.	106
Abbildung 47: Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).	107

Abbildung 48: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Hauptgruppe.	108
Abbildung 49: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	109
Abbildung 50: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	110
Abbildung 51: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Hauptgruppe.	111
Abbildung 52: Konfusionsmatrizen für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).	112
Abbildung 53: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Untergruppe.	113
Abbildung 54: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	114
Abbildung 55: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	115
Abbildung 56: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Untergruppe.	116
Abbildung 57: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Detailklassen.	118
Abbildung 58: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	120
Abbildung 59: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	121
Abbildung 60: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Detailklassen.	122
Abbildung 61: Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).	123
Abbildung 62: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Hauptgruppe.	124
Abbildung 63: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.	125
Abbildung 64: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.	126
Abbildung 65: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Hauptgruppe.	127
Abbildung 66: Konfusionsmatrizen für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).	129
Abbildung 67: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Untergruppe.	129

Abbildung 68: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.....	131
Abbildung 69: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.....	132
Abbildung 70: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Untergruppe. ....	133
Abbildung 71: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Detailklassen. ....	134
Abbildung 72: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0. ....	137
Abbildung 73: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1. ....	138
Abbildung 74: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Detailklassen.....	139
Abbildung 75: Veränderung des F-Maßes durch Synergieeffekte der Klassen der Hauptgruppe basierend auf weichen Merkmalen. ....	140
Abbildung 76: Veränderung des F-Maßes durch Synergieeffekte der Klassen der Untergruppe basierend auf weichen Merkmalen. ....	140
Abbildung 77: Veränderung des F-Maßes durch Synergieeffekte der Detailklassen basierend auf weichen Merkmalen.....	141
Abbildung 78: Veränderung des F-Maßes durch Synergieeffekte aller Klassen basierend auf weichen Merkmalen.....	141
Abbildung 79: Variation der Reflexion (380-880 nm) einer Buchenart im Zeitraum von April bis November (Quelle: Kodani et al, 2002).....	143
Abbildung 80: Vergleich des anhand des <i>Random Forst</i> erzielten F-Maß mit und ohne Merkmalsauswahl für den Entwicklungsdatensatz Rostock und die Übertragbarkeitsdatensätze Rostock und Groitzsch. ....	146
Abbildung 81: Zusammenhang zwischen der Anzahl der Trainingspunkte und dem resultierenden F-Maß für die Klassen der Hauptgruppe.....	146
Abbildung 82: Zusammenhang zwischen der Anzahl der Trainingspunkte und dem resultierenden F-Maß für die Klassen der Untergruppe.....	147
Abbildung 83: Zusammenhang zwischen der Anzahl der Trainingspunkte und dem resultierenden F-Maß für die Detailklassen.....	147
Abbildung 84: Vergleich der Gesamtgenauigkeit, des Kappa-Koeffizienten und der klassifizierten Fläche in Abhängigkeit von der relativen Häufigkeit (0 und 1), der Klassifikationsebene sowie dem Untersuchungsgebiet. ....	148
Abbildung 85: Absolute Abweichung [%] der tatsächlichen Anwendung findenden Merkmalskategorien vom Anteil der Merkmalskategorie an der Gesamtmerkmalsanzahl [%] je Datensatz.....	153

# Tabellenverzeichnis

Tabelle 1: Gegenüberstellung der Biotopkartierung und der Biotop- und Nutzungstypenkartierung in Mecklenburg-Vorpommern (Quelle: LUNG, 1998).....	9
Tabelle 2: Unterschiede der Kartierschlüssel dargestellt anhand des Grünlandes (Tabelle nach FRIETSCH & SCHERFKE, 2011, Datenbasis: LFULG, 2010, LFUG, 2003, BUDER ET AL., 2004, EUNIS, 2014) .....	12
Tabelle 3: RapidEye Produkttypen .....	33
Tabelle 4: Überblick über den TerraSAR-X Stripmap Modus (SM) .....	34
Tabelle 5: Parametrisierung und Genauigkeiten der Orthorektifizierung .....	38
Tabelle 6: Kalibrationskoeffizienten der RapidEye-Szenen des Untersuchungsgebietes Rostock. ....	39
Tabelle 7: Kalibrationskoeffizienten der RapidEye-Szenen des Untersuchungsgebietes Groitzsch. ....	39
Tabelle 8: Reflektanzen im Vergleich mit den Referenzmessungen und den Fehlergrenzen. ....	40
Tabelle 9: Verwendete Merkmale in der Biotoptypen- und Landnutzungskartierung. ....	50
Tabelle 10: Evaluation der Klassifikationsgüte unter Verwendung unterschiedlicher Baumtiefen für den RF-Klassifikator. ....	63
Tabelle 11: Evaluation der Klassifikationsgüte und Laufzeit unter Verwendung unterschiedlicher Baumanzahl für den RF-Klassifikator.....	64
Tabelle 12: Übersicht über die Evaluation der Trennbarkeitsmaße. ....	71
Tabelle 13: Ergebnisse und Parameter der Kernel Evaluation der Klassen der Hauptgruppe.....	73
Tabelle 14: Detailklassen der Baumvegetation und verwendete harte Merkmale. ....	81
Tabelle 15: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Hauptgruppe.....	89
Tabelle 16: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	91
Tabelle 17: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Untergruppe.....	96
Tabelle 18: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	96
Tabelle 19: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Detailklassen. ....	101
Tabelle 20: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Detailklassen für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	103
Tabelle 21: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Hauptgruppe.....	107
Tabelle 22: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	108
Tabelle 23: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Untergruppe.....	112

Tabelle 24: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	113
Tabelle 25: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Detailklassen.....	117
Tabelle 26: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Detailklassen für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	119
Tabelle 27: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Hauptgruppe.....	123
Tabelle 28: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	124
Tabelle 29: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Untergruppe.....	128
Tabelle 30: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	128
Tabelle 31: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Detailklassen.....	135
Tabelle 32: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Detailklassen für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).....	135

# Abkürzungsverzeichnis

ADS	Airborne Digital Sensor
AFI	Area Fit Index
ALOS	Advanced Land Observing Satellite
AOI	Area of Interest
ATCOR	Atmospheric Correction
ATKIS	Amtliches Topographisch-Kartographisches Informationssystem
Bagging	Bootstrap aggregating
BAP	Biodiversity Action Plan
BK	Biotopkartierung
BNTK	Biotop- und Landnutzungskartierung
BLNTK	Biotop- und Landnutzungskartierung
BTK	Biotoptypenkartierung
CAP	Common Agricultural Policy
CCD	Charge-coupled Device
CBD	Convention on Biodiversity
CE90	Circular Error of 90%
CIR	Colored Infrared
CLC	CORINE Land Cover
CORINE	Coordination of Information on the Environment
CSV	Comma-separated values
DEFRA	Department for Environment, Food and Rural Affairs
DGM	Digitales Geländemodell
DOM	Digitales Oberflächenmodell
DOP	Digitale Orthophotos
DVI	Difference Vegetation Index
EODHaM	Earth Observation Data for Habitat Monitoring
EUNIS	European Nature Information System
ETM+	Landsat Enhanced Thematic Mapper Plus
EVI	Enhanced Vegetation Index
FAO	Food and Agriculture Organization
FFH	Fauna-Flora-Habitat
FLAASH	Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes
GCP	Ground Control Point
GDAL	Geospatial Data Abstraction Library
GEMI	Global Environment Monitoring Index
GHCs	General Habitat Categories
GIS	Geographischen Informationssystem
GLCM	Grey level co-occurrence matrix
GNDVI	Green Normalized Difference Vegetation Index
GRVI	Green Ratio Vegetation Index
HRG	High Resolution Geometric
HRSC	High Resolution Stereo Camera
HS	High Resolution Spotlight Modus
ICA / IC	Independent Components Analysis
k. A.	keine Angaben

LANA	Bund-Länderarbeitsgemeinschaft Naturschutz, Landschaftspflege und Erholung
LCCS	Land Cover Classification System
LiDAR	Light detection and ranging
LPIS	Land Parcel Information Service
MLC	Maximum-Likelihood-Classification
ms	multispektral
MNF	Minimum Noise Fraction
MTF	Modulation Transfer Function
NDGI	Normalized Difference Green Index
nDOM	normalisiertes Digitales Oberflächenmodell
NDVI	Normalized Difference Vegetation Index
NITF	National Imagery Transmission Format
NIR	nahes Infrarot
NN	Normalnull
OM	Over Merging
OSM	OpenStreetMap
PALSAR	Phased Array type L-band Synthetic Aperture Radar
PCA	Principle Components Analysis
P1S	Phase 1 Survey
RF	Random Forest
RMSE	Root Mean Square Error
RSGISLib	Remote Sensing GIS Library
RVI	Ratio Vegetation Index
SAR	synthetic aperture radar
SAVI	Soil Adjusted Vegetation Index
SC	ScanSAR Modus
SL	Spotlight Modus
SM	Stripmap Modus
SMA	Spectral mixture analysis
SVM	Support-Vector-Machine
SWIR	kurzwelliges Infrarot (englisch: short wavelength infrared)
UM	Under Merging
USGS	United States Geological Survey
UTM	Universal Transverse Mercator System
Pan	panchromatischer Kanal
PCA	Principal Component analysis
WFD	Water Framework Directive
WGS	World Geodetic System
XML	Extensible Markup Language





# 1 Einleitung

---

*“Natural and semi natural habitats are exposed to growing pressure due to intensification of agricultural land use, tourism, development and other activities [...] conservation and sustainable land use of such areas have a high priority in environmental policy and administration. [...] prerequisite for an effective conservation strategy is a continuous and consistent monitoring programme on the state and spatial extent of sensitive habitats.”*

BOCK, M. (2003): Remote sensing and GIS-based techniques for the classification and monitoring of biotopes Case examples for a wet grass- and moor land area in Northern Germany. *Journal for Nature Conservation*, 11, 145-155.

---

## 1.1 Motivation

Um den Anforderungen der nationalen und internationalen Naturschutzrichtlinien, z.B. die Kartierung der Lebensraumtypen des Anhangs I der Flora-Fauna-Habitat Richtlinie (FFH-Richtlinie) zu entsprechen, ist die Entwicklung detaillierter Biotoptypen-, Landbedeckungs- und Landnutzungskartierungen von entscheidender Bedeutung. Unter dem Einfluss des Klimawandels und dem zunehmenden Druck des Menschen auf die Ökosysteme ist das Hauptziel dieser Initiativen der Schutz und die Überwachung der Biotoptypen (BALZER, 2000, PETERS, 2004, GÄHLER, 2006). Um die z.B. durch die *Convention on Biodiversity* (CBD) definierten Ziele zu erreichen ist eine umfassende Kartierung und Überwachung aller Landflächen unabdingbar. Die Ziele der CBD beinhalten unter anderem, dass alle Biotop- und Landnutzungstypen nachhaltig behandelt werden, um den Erhalt der Biodiversität zu gewährleisten, beziehungsweise die Biodiversität regional zu erhöhen (QUI ET AL., 2010).

In Deutschland ist die Biotoptypenkartierung (BTK) zu einer wichtigen Quelle für die Identifizierung und Abschätzung von Biotop-, Biototyp- und Landnutzungsinformationen geworden (ZEPP & MÜLLER, 1999, GÄHLER, 2006). Die BTK, also die „Inventarisierung der Landschaft nach naturschützerischen Gesichtspunkten (VAHLE, 1990)“ dient dem Zweck: „schleichende Veränderungen zu erkennen, Naturschutzmaßnahmen zu planen, die Flurbereinigung zu unterstützen sowie um als Argumentationshilfe bei geplanten Eingriffen und allgemein der Eingriffsregelung zu dienen (VAHLE, 1990).“

Traditionelle Überwachungsansätze wie die visuelle Interpretation von Luftbildern oder der Geländebegehung sind jedoch sehr zeit- und kostenintensiv. Darüber hinaus ist aufgrund der Subjektivität der Aufnahme und Verarbeitung der Daten eine Vergleichbarkeit erschwert und die räumliche Abgrenzung der Biotoptypen nicht akkurat realisierbar (LESER, 2003, BOCK, 2005, GÄHLER, 2006). Das übergeordnete Ziel dieser Arbeit ist es zu evaluieren, in welchem Umfang die synergistische Verwendung von modernen Erdbeobachtungsdaten und –methoden zur Kartierung von Biotoptypen- und Landnutzungsinformationen beitragen kann.

## 1.2 Zielstellung und Gliederung

Die Ziele, Forschungsfragen sowie die Gliederung der vorliegenden Arbeit werden im Folgenden aufgezeigt.

Das übergeordnete Ziel der Arbeit ist *die Kartierung von Biotoptypen mittels Merkmalsauswahl und objekt-basierter, synergistischer Klassifikation*. Um eine möglichst breite Anwendbarkeit der Methode zu gewährleisten, sollen drei weitere Ziele verfolgt werden:

1. Die Übertragung der entwickelten Methode auf ein weiteres Untersuchungsgebiet mit ähnlicher Datengrundlage und vergleichbarer, resultierender Genauigkeit.
2. Die Übertragung der entwickelten Methode auf eine andere Datengrundlage mit vergleichbarer, resultierender Genauigkeit.
3. Die Vorteile der synergistischen Verwendung von Fernerkundungsdaten beweisen.

Aus den definierten Zielen ergeben sich die folgenden Forschungsfragen, welche im Laufe der Arbeit beantwortet werden sollen:

1. Welche Merkmale und Merkmalskategorien lassen sich aus den vorhandenen Fernerkundungsdaten erzeugen?
2. Welche Klassifikationsmethode eignet sich für die Erfassung von Biotoptypen?
3. Welche Methode eignet sich zur Merkmalsauswahl?
4. Ist die Übertragung des Algorithmus auf andere Untersuchungsgebiete und andere Datengrundlagen möglich?
5. Verbessert die Synergie aus passiven und aktiven Fernerkundungsdaten die Klassifikationsgenauigkeit?
6. Welche Merkmalskategorien spielen die größte Rolle bei der Klassifikation?

Die vorliegende Arbeit gliedert sich in die Einleitung, die Grundlagen, den Stand der Forschung, die Arbeitsbasis, die Wissensbasis und Methoden, die Ergebnisse und die Zusammenfassung und Diskussion.

In der *Einleitung* werden die Motivation und Zielsetzung sowie die Gliederung vorgestellt.

In den *Grundlagen* werden das Basiswissen zum Thema Fernerkundung und der Klassifikation von Fernerkundungsdaten kurz erläutert und die Begrifflichkeiten im Bereich der Biotope, Biotoptypen und Landschaftselemente definiert.

Im Kapitel *Stand der Forschung* werden die traditionellen Methoden zur Kartierung von Biotopen und Biotoptypen sowie nationale und internationale Kartierungssysteme vorgestellt. Anschließend werden anhand der Literatur bisherige Arbeiten im Bereich der Biotoptypenkartierung mittels verschiedener Fernerkundungsdaten beziehungsweise der methodisch naheliegenden Kartierung der Landbedeckung und Landnutzung betrachtet. Das Kapitel schließt mit dem Stand der Forschung im Bereich der Merkmalsauswahl für die Klassifikation ab.

Im Kapitel *Arbeitsbasis* werden die Untersuchungsgebiete, die verwendeten Daten, die Vorverarbeitung der Fernerkundungsdaten sowie das Klassifikationsziel vorgestellt.

Im *Methodenkapitel* werden die Erzeugung der Wissensbasis, im Speziellen die Auswahl der Merkmale, der Klassifikationsansatz, die Methodik zur Merkmalsauswahl, getrennt in Merkmalsranking und Merkmalsreduktion, sowie die Methodik zur Evaluation der Synergie beschrieben.

Im *Ergebnisteil* werden die Resultate der Merkmalsauswahl und der Klassifikation für die verschiedenen Untersuchungsgebiete und Datenquellen sowie die Ergebnisse der Segmentierung und die Synergieeffekte gezeigt.

In der *Zusammenfassung und Diskussion* werden die verwendeten Daten, Methoden und Ergebnisse im Rahmen der Literatur eingeordnet, diskutiert und ein Ausblick auf mögliche Erweiterungen und Anwendungen der Methode gegeben.

# 2 Grundlagen

---

*"Everything is related to everything else, but near things are more related than distant things."*

Tobler W. (1970): A computer movie simulating urban growth in the Detroit region. *Economic Geography*. 46, 234-240.

---

Im Kapitel 2 wird ein Kurzüberblick über die Grundlagen der Fernerkundung sowie der in diesem Forschungsbereich verwendeten Klassifikationsmethoden gegeben. Auf eine umfassende Abhandlung dieser Grundlagen wird verzichtet und stattdessen ein Verweis auf tiefergehende Literatur integriert. Grundlegende Aspekte, welche eine hohe Relevanz für die Arbeit beinhalten, werden im Stand der Forschung (Kapitel 3) aufgegriffen und vertieft.

## 2.1 Fernerkundung

Fernerkundung bezeichnet die Wissenschaft der Beobachtung eines Objektes, einer Fläche oder eines Phänomens auf der Erdoberfläche ohne direkten Kontakt (GAO, 2006). Zur Anwendung kommen Daten aufgezeichnet von flugzeuggestützten Aufnahmesystemen oder Satellitensensoren (LILLESAND & KIEFER, 2008). Aufgenommen und analysiert werden Daten von Objekten der Erdoberfläche, welche elektromagnetische Strahlung emittieren oder reflektieren. Die elektromagnetische Strahlung und die zum Einsatz kommenden Sensoren werden in der Fernerkundung anhand ihrer Wellenlänge eingeordnet. Unterschieden werden aktive Systeme, welche selbst ausgestrahlte, rückgestreute Energie aufzeichnen (z.B. Radarsysteme) und passive Systeme, welche Energie, emittiert oder reflektiert durch das beobachtete Objekt, erfassen. Objekte auf der Erdoberfläche besitzen charakteristische spektrale Verläufe über die verschiedenen Wellenlängenbereiche hinweg beziehungsweise Rückstreuintensitäten in den verschiedenen Polarisationen. Die aufgezeichneten Informationen jedes Bandes werden je nach räumlicher, radiometrischer und spektraler oder polarimetrischer Information des Sensors in ein 2-dimensionales Feld (*Array*) abgespeichert. Die räumliche Auflösung beschreibt die Größe des Pixels im Bild in x- und y-Richtung. Die radiometrische Auflösung beschreibt den Wertebereich der Daten. Die spektrale Auflösung beschreibt den abgedeckten Wellenlängenbereich des elektromagnetischen Spektrums und die Anzahl der Kanäle. Des Weiteren besitzt jeder Sensor eine zeitliche Auflösung, welche den Zeitabschnitt beschreibt, in dem ein Sensor zweimal denselben Punkt der Erdoberfläche überfliegt beziehungsweise aufzeichnen kann.

Auf eine detaillierte Darstellung der Grundlagen der optischen und SAR-Systeme wird an dieser Stelle, aufgrund der umfangreichen Literatur, verzichtet. Zu physikalischen Grundlagen der Fernerkundung geben z.B. REES (2001) oder SCHOWENGERDT (1997) einen umfangreichen Überblick. Bezüglich Anwendungen und Methoden sei auf ALBERTZ (2001), SCHOWENGERDT (1997), LILLESAND & KIEFER (2008), JENSEN (2004) und JENSEN (2007) verwiesen.

Speziell mit den LiDAR-Grundlagen befassen sich WAGNER ET AL. (2003), mit den Grundlagen der hyperspektralen Fernerkundung BORENGASSER ET AL. (2007) und die SAR-Grundlagen und Anwendungen werden in MASSONNET & SOUYRIS (2008), HENDERSON & LEWIS (1998) und ULABY ET AL. (1986A) dargestellt.

## 2.2 Klassifikation

Die Klassifikation im Kontext der Verarbeitung von Fernerkundungsdaten bezeichnet die Zuweisung eines Bildelementes, welches ein Pixel, Segment oder Objekt sein kann, zu einer Klasse. Die Klasse wird durch, die spezifischen, den Bildelementen inhärenten, Merkmale definiert. Anhand der Methode der Eingrenzung der Merkmale für die verschiedenen Klassen können im Klassifikationsverlauf die Bildelemente den Klassen zugewiesen werden. Die grundlegendste Unterscheidung zwischen Klassifikationsmethoden ist wohl die Trennung zwischen pixel-basierten Ansätzen und segment-beziehungsweise objekt-basierten Ansätzen.

Pixel-basierte Ansätze ordnen Pixel, anhand der individuellen Charakteristik bestimmter Merkmale, wie zum Beispiel der Reflexionswerte, einer Klasse zu (JENSEN, 2004, GONG ET AL., 1992, CASALS-CARRASCO ET AL., 2000). Eine Vielzahl von Methoden und zugehörige Anwendungen wurden auf der Grundlage des pixel-basierten Ansatzes entwickelt. Die Schwächen der pixel-basierten Ansätze liegen zum einen darin, dass lediglich die spektralen Informationen und die direkt daraus ableitbaren Merkmale wie die Textur jedoch keine Informationen aus dem Kontext der benachbarten Pixel in die Klassifikation eingehen und zum anderen entsteht ein vergleichsweise sehr inhomogenes Klassifikationsbild (DEAN & SMITH, 2003, QIAN, 2007:164, ZHOU & ROBSON, 2001). Ein entscheidender Vorteil dieser Methodik ist, dass jeder Pixel separat betrachtet und entsprechend zugeordnet wird – die sogenannte harte Klassifikation. Damit ist eine eindeutige Klassenherleitung möglich.

Beim segment- beziehungsweise objekt-basierten Ansatz ist zunächst eine Definition der Begrifflichkeiten nötig. Als Segment wird eine aus Pixel, anhand von vorher definierten Homogenitätskriterien, geschaffene Bildeinheit bezeichnet. Ein Segment kann, muss aber keine realweltliche Entsprechung haben. Als Objekt wird dagegen eine aus Pixel, anhand von vorher definierten Homogenitätskriterien, geschaffene Bildeinheit bezeichnet, welche eine realweltliche Entsprechung besitzt. Dies kann z. B. ein aus LiDAR-Daten anhand einer Segmentierung erzeugtes Haus- oder Baumobjekt sein. Im Folgenden wird nur noch von objekt-basierten und dementsprechend auch von Objekten gesprochen.

Grundlegend für diese Art der Bildverarbeitung ist die Bildsegmentierung (Kapitel 5.2.1 und 6.2). Diese geht der eigentlichen Klassifikation voraus und bezeichnet den Schritt der Erstellung von Objekten aus Pixel. Wie bereits angedeutet werden beim objekt-basierten Ansatz im Gegensatz zu den pixel-basierten Ansätzen nicht einzelne Pixel, sondern Objekte bestehend aus „ähnlichen“ Pixel betrachtet (GAO, 2006, QIAN, 2007).

Ein weiterer Unterschied ist, dass hier eine Bildeinheit einer oder mehreren Klassen angehören kann. Die Zugehörigkeit zu einer Klasse basiert auf der weichen Klassifikation oder auch *Fuzzy Logic* und jedes Objekt erhält eine Zugehörigkeit zu einer Klasse zwischen 0.0 (keine Zugehörigkeit zu der betrachteten Klasse) und 1.0 (absolute Zugehörigkeit zu der Klasse). Der Grad an Übereinstimmung ist davon abhängig, ob und in welchem Maße ein Objekt die Klassendefinition erfüllt (GAO, 2006, QIAN, 2007). Die *Fuzzy Logic* kann jedoch auch durch einen festen Schwellwert ersetzt werden. Weiterhin bietet ein objekt-basierter Ansatz den Vorteil, Beziehungen zwischen den Objekten sowohl in der Nachbarschaft, als auch hierarchisch herzustellen.

Hieraus resultieren neue Möglichkeiten des Klassifikationsdesigns. Eine Vielzahl von Autoren sehen in der objekt-basierten Klassifikation Vorteile gegenüber der pixel-basierten Klassifikation.

BOCK ET AL., 2005 sehen grundlegende Vorteile im Design des objekt-basierten Klassifikationssystems durch die Möglichkeit zur Integration von zusätzlichen Daten und der Definition von wissensbasierten Regeln und Klassenbeschreibungen. Nur somit ist es z.B. möglich spektrale Informationen mit LiDAR-Informationen und Nachbarschaftsbeziehungen in einer Klassenbeschreibung zu verknüpfen. HOFFMANN ET AL., 2000 hinterlegt dies mit einem Beispiel. Er führt an, dass Straßen und Dächer aus

dem gleichen Material spektral nicht separierbar sind und deshalb weitere (Kontext-)Informationen nötig sind. BENZ ET AL., 2004 erweitern dies und nennen als Vorteile die auf den Objekten basierenden aussagekräftigen Statistik- und Texturberechnungen, den durch Form- und Topologiemerkmale erweiterten, nicht korrelierten Merkmalsraum und die enge Beziehung zwischen abgeleiteten Objekten und den Objekten in der realen Welt.

BLASCHKE & STROBL, 2001 führen aus, dass pixel-basierte Methoden nicht mehr fähig sind mit räumlich sehr hoch-aufgelösten Daten umzugehen, da die Pixel im Bild kein Objekt mehr darstellen, sondern vielmehr einen Teil eines Objektes und somit eine Klassenzuweisung erheblich erschwert wird.

## 2.3 Biotop, Biotoptyp und Landschaftselemente

Im Folgenden werden die Konzepte hinter den Begriffen der Biotope, Biotoptypen und Landschaftselementen erläutert. Zunächst kann grob zwischen terrestrischen und marinen Systemen unterschieden werden. In den folgenden Definitionen wird der Fokus nur auf die terrestrischen Ausprägungen gelegt.

Der Begriff *Biotop* geht zurück auf DAHL, 1908 (OLENIN & DUCROTOY, 2006). DAHL, 1908 verwendete den Begriff Biotop um einen Faktorenkomplex zu definieren, welcher die physikalischen Bedingungen für die Existenz einer Artengemeinschaft (Biozönose) beschreibt (OLENIN & DUCROTOY, 2006). MÖBIUS, 1877 beschreibt als Erster eine Austernbank als Biozönose beziehungsweise Artengemeinschaft und definiert somit diese Begrifflichkeit und gleichzeitig die Grundlage für die Ökologie (KELLER & GOLLEY, 2000, OLENIN & DUCROTOY, 2006).

TANSLEY, 1935 beschreibt als Ökosystem die physikalischen Bedingungen und die Artengemeinschaft, bestehend aus Pflanzen und lebenden Tieren. Dies erweitert TISCHLER, 1955, indem er für die physikalischen Bedingungen (abiotischen Faktoren) den Begriff Biotop und für die biotische Gemeinschaft den Begriff Biozönose verwendet und diese über die Formel: Biotop + Biozönose = Ökosystem verknüpft (NEHRING & ALBRECHT, 2000, OLENIN & DUCROTOY, 2006). Eine allgemeine Definition im deutschsprachigen Raum für das Biotop erarbeitet STREIT, 1992: „Als „das“ Biotop wird umgangssprachlich oft auch ein naturnah belassenes oder eingerichtetes Areal bezeichnet, das einer größeren Zahl wildlebender Organismen Lebensraum bieten kann (STREIT, 1992, NEHRING & ALBRECHT, 2000).“ Im angelsächsischen Sprachraum wird meist *habitat* als Synonym für Biotop, bei einigen Autoren auch *ecotop*, als „eine in ihrer Vegetationsstruktur, Sukzessionsstadium und abiotischen Faktoren homogene, räumliche Landschaftseinheit“ verwendet (LEUVEN ET AL., 2002, STRAATSMA & BAPTIST, 2008).

Der Begriff *Biotoptyp* wird durch RIECKEN ET AL., 2006 als „abstrahierter Typus aus der Gesamtheit gleichartiger Biotope“ bezeichnet und „bietet mit seinen ökologischen Bedingungen weitgehend einheitliche, von anderen Typen verschiedene Voraussetzungen für Lebensgemeinschaften“ (LUNG, 2010). Die Typisierung nach RIECKEN ET AL., 2006 „schließt abiotische (z. B. Feuchte, Nährstoffgehalt) und biotische Merkmale (Vorkommen bestimmter Vegetationstypen und -strukturen, Pflanzengesellschaften, Tierarten) ein“ (LUNG, 2010). Des Weiteren wird „die Mehrzahl der Biotoptypen Mitteleuropas in ihrer konkreten Ausprägung zudem durch die historischen oder aktuellen anthropogenen Nutzungen (Landwirtschaft, Forstwirtschaft, Verkehr usw.) und Beeinträchtigungen (Eutrophierung, Schadstoffe usw.) geprägt (RIECKEN ET AL., 2006)“ (LUNG, 2010).

Das Biotop beziehungsweise der Biotoptyp sind in dieser Arbeit und im Bereich der Landesämter für Natur und Umwelt „wertfreie Begriffe, die sich auf die gesamte Landschaft anwenden lassen (LUNG, 2010).“ Der „ursprüngliche Begriff als Lebensraum von Pflanzen und Tieren kann in dieser Form im

Rahmen der Biotopkartierung nicht angewendet werden, da die Biotope vorwiegend mit Hilfe ihrer Vegetation und Struktur abgegrenzt werden (LUNG, 2010).“

Die Landschaftselemente definieren sich nach FORMAN & GODRON, 1986 als „die kleinste kartierbare, relativ homogene Einheit.“ WALZ, 2004 und WALZ, 2013 beschreiben ein Landschaftselement als „kleinste homogene Einheit, auch als Ökotope oder Landschaftszelle bezeichnet“. Somit bilden die Landschaftselemente Untergruppen in den Biotopen beziehungsweise Biotoptypen. Dieser Sachverhalt wird in der Definition nach REMY (2011), welcher Landschaftselemente als „eindeutig von ihrer Umgebung abgrenzbare punktuelle, lineare oder flächenhafte Landschaftsbestandteile unterschiedlicher Größe, deren jeweilige strukturelle Homogenität aus einheitlichen Standort- oder Nutzungsbedingungen resultiert“ noch deutlicher.

# 3 Stand der Forschung

---

*„Die Zeit wird kommen, wo unsere Nachkommen sich wundern, da wir so offenbare Dinge nicht gewusst haben.“*

Lucius Annaeus Seneca (4 v.Chr. - 65 n.Chr.)

---

In Kapitel 3 wird der für diese Arbeit relevante Stand der Forschung im Bereich der traditionellen Biotoptypenerfassung, nationaler und regionaler Monitoringansätze, Klassifikationssystemen und der Fernerkundung für die Biotoptypenerfassung dargestellt. Im ersten Teil wird auf die traditionelle Biotoptypenerfassung eingegangen. Diese Methoden verwenden vor allem in-situ Erfassungen für die Kartierung der Biotoptypen. Fernerkundungsdaten dienen hierbei nur als Zusatzinformation. Anschließend werden nationale beziehungsweise regionale Monitoringansätze vorgestellt und auf deren zugrundeliegende Klassifikationssysteme eingegangen. Im letzten Teil dieses Kapitels wird anhand von ausgewählter Literatur der Stand der Forschung im Bereich der Biotoptypen- sowie Landschaftselementkartierung anhand verschiedener Fernerkundungsdaten ausführlich dargestellt.

Die ersten Aktivitäten im Bereich der Biotoptypenkartierung für den Umweltschutz und die Landschaftsplanung wurden in der Bundesrepublik Deutschland in den siebziger Jahren durchgeführt (SUKOPP & WEILER, 1988). In den für diese Arbeit zu Grunde liegenden Bundesländern Mecklenburg-Vorpommern (LFUG, 2004) und Sachsen wurden die ersten Biotoptypenkartierungen 1994 in Sachsen respektive 1996 in Mecklenburg-Vorpommern (LUNG, 1998) abgeschlossen.

Die in Deutschland durch die Bundesländer definierte Verfahren und Klassensysteme für die Biotoptypenerfassung sind keineswegs einzigartig im weltweiten Vergleich. Die Erfassung und Überwachung von Biotoptypen für die Herstellung von Karten mit dem Hintergrund der Landschaftsplanung werden in Nationen weltweit (Schweden (LÖFVENHAFT ET AL., 2002), Korea (HONG ET AL., 2005), Türkei (MANSUROGLU ET AL., 2006, YILMAZ ET AL., 2010)) ebenso durchgeführt (QUI, 2010). Ein weiteres dem deutschen System zur Biotoptypenerfassung sehr ähnliches System (QUI ET AL., 2010) ist die vom *Nature Conservancy Council* in Großbritannien durchgeführte *Phase 1 Habitat Survey* (JNCC, 2007).

Nichtdestotrotz variieren die verwendeten Methoden, Daten und Klassen von Land zu Land und in Deutschland auch von Bundesland zu Bundesland. Im Folgenden wird auf die verwendeten Methoden, Klassifikationssysteme und die Erfassung der Biotoptypen mittels Fernerkundung eingegangen.



### 3.1 Traditionelle Methoden der Biotoptypenkartierung

Die traditionellen Methoden der Biotoptypenkartierung werden überwiegend in die selektive und die flächendeckende Biotoptypenerfassung unterteilt (WITTIG & SCHREIBER, 1983, SUKOPP & WEILER, 1988, LESER, 2003, YILMAZ ET AL., 2010, QUI ET AL., 2010). Darüber hinaus findet in einigen Fällen die repräsentative Biotoptypenerfassung Anwendung (YILMAZ ET AL., 2010).

Das Ziel der selektiven Biotoptypenkartierung ist die Identifizierung von Flächen mit schützenswerten beziehungsweise potenziell schützenswerten Biotoptypen (HONG ET AL., 2005 in QUI ET AL., 2010, YILMAZ ET AL., 2010). Als schützenswert beziehungsweise ökologisch wertvoll gelten nach JARVIS & YOUNG (2005) Biotoptypen, welche einen der folgenden Kriterien erfüllen:

1. Artenreichtum mit einigen seltenen Arten,
2. eine hohe strukturelle Diversität und/oder
3. eine Rückzugsmöglichkeit für Tiere und Pflanzen welche durch intensive Landnutzung aus anderen Gebieten verdrängt wurden (QUI ET AL., 2010).

In Deutschland ist die Definition von ökologisch wertvollen Biotoptypen gesetzlichen Richtlinien (z.B. § 20 des Landesnaturschutzgesetzes (LNatGM-V) in Mecklenburg-Vorpommern und § 26 des Sächsischen Naturschutzgesetzes (SächsNatSchG) (LUNG, 1998, LFUG, 2004)) unterworfen. Die Erfassung der Biotoptypen auf den identifizierten Flächen wird mittels in-situ Kartierungen sowie der unterstützenden Verwendung von bereits vorhandenen, zum Teil digitalen Karten und Luftbildern durchgeführt.

Die flächendeckende Biotoptypenkartierung erfasst alle in einem Gebiet vorhandenen Biotoptypen. Dieser Ansatz verbindet in-situ Kartierungen durch ausgebildete Gutachter und die Auswertung von CIR-Luftbildern. Alle Flächen werden anhand der Feld- und CIR-Kartieranleitungen erfasst und klassifiziert und in Karten mit einem Maßstab von 1:5000 beziehungsweise 1:10000 überführt (QUI ET AL., 2010). Das *Institut für Landschaftsforschung und Naturschutz* hat für Brandenburg, Mecklenburg-Vorpommern, Sachsen, Sachsen-Anhalt und Thüringen einen Standard für ein Klassifikationssystem mittels Luftbildauswertung erarbeitet (LESER, 2003). Die ersten flächendeckenden Biotoptypenkartierungen für Mecklenburg-Vorpommern beziehungsweise Sachsen wurden 1996, respektive 1994 fertiggestellt.

Eine vergleichsweise selten verwendete Methode ist die repräsentative Biotoptypenkartierung. Bei dieser Herangehensweise werden Referenzflächen für alle in einem Gebiet vorkommenden Biotoptypen definiert. Diese Flächen werden in-situ kartiert und die Ergebnisse anschließend auf Gebiete übertragen welche eine ähnliche Biotoptypenstruktur aufweisen (YILMAZ ET AL., 2010).



### 3.2 Monitoringansätze

National, international und auf Länderebene haben sich standardisierte Methoden zur Biotoptypenerfassung etabliert. Im Folgenden werden die deutsche *Biotopkartierung* beziehungsweise *Biotop- und Nutzungstypenkartierung* und die britische *Phase 1 Habitat Survey* vorgestellt.

Die Kartierung von Biotopen, basierend auf den Naturschutzgesetzen der deutschen Länder, kann in zwei Verfahren unterteilt werden:

1. Biotopkartierung (BK) und
2. Biotop- und Nutzungstypenkartierung (BNTK/BTLNK).

Tabelle 1 stellt beide Verfahren einander gegenüber. Die größten Unterschiede liegen hierbei bei der Art der Erfassung der Daten und dem erreichten Klassifikationsdetail. Die BNTK basiert auf Luftbildauswertungen und bietet einen geringeren Detailgrad gegenüber der BK, welche direkt im Gelände erfasst wird und somit einen deutlich erhöhten Klassifikationsdetailgrad bietet.

Tabelle 1: Gegenüberstellung der Biotopkartierung und der Biotop- und Nutzungstypenkartierung in Mecklenburg-Vorpommern (Quelle: LUNG, 1998)

	<b>Biotop- und Nutzungstypenkartierung</b>	<b>Biotopkartierung</b>
vollständige Bezeichnung	Biotop- und Nutzungstypenkartierung durch CIR-Luftbildauswertung	Biotopkartierung im Gelände
Abkürzung	BNTK	BK
Maßstab	1:10000	verschiedene Maßstäbe jedoch flächendeckend im Maßstab 1:25000 (für die Kartierung geschützter Biotope 1:10000)
Methodik	stereoskopische Interpretation von Color-Infrarot-Luftbildern	Aufnahme der Biotope durch Geländebegehung
vorliegende Informationen	Typisierung der Fläche mit Angaben zur im Luftbild erkennbaren Struktur	neben einer Typisierung detaillierte Angaben zu Standort, Vegetation, ökologischem Wert, Gefährdungen etc.
Form der Information	Codierung der Fläche in der Karte	ausführliche, codierte und beschreibende Angaben in Erfassungsbogen (beziehungsweise Datenbank), Fotodokumentation
Flächendeckung	landesweit flächendeckend	- landesweit selektiv für bestimmte Biotoptypen (geschützte Biotope) - selektiv oder flächendeckend für einzelne Räume
Verfügbarkeit	landesweit verfügbar	- Beginn der Kartierung geschützter Biotope im Jahr 1996, Abschluss der ersten Kartierung im Jahr 2002 - weitere selektive und flächendeckende Kartierung einzelprojektbezogen
digitale Datenhaltung	Geometriedaten: ArcInfo	Geometriedaten: ArcInfo, zusätzliche Sachdaten: dBase

Jedes Bundesland führt basierend auf den jeweiligen Landesnaturschutzgesetzen eine Kartierung der Biotope durch. Für Sachsen definieren die zuständigen Landesämter den Bedarf für

1. die BNTK „Aufgrund der wirtschaftlichen Umstrukturierung und Weiterentwicklung Sachsens sowie dem damit einhergehenden erhöhten Flächenbedarf für Gewerbe-, Siedlungs- und

Infrastrukturentwicklung, besteht der dringende Bedarf an aktuellen Bestandsdaten, einerseits über die Realnutzung der Landesoberfläche, andererseits über ihre naturräumliche Ausstattung (LfULG, 1994 & 2010).“

2. die BK „Nach § 43 des Sächsischen Naturschutzgesetzes (SächsNatSchG) hat das Sächsische Landesamt für Umwelt und Geologie (LfUG) die Aufgabe, einheitliche Grundsätze für die Durchführung der Biotopkartierung aufzustellen, die landesweite Biotopkartierung auszuwerten und laufend zu aktualisieren (LfUG, 2003).“

Im Folgenden werden ergänzend zu Tabelle 1 weitere Details zur BNTK und BK beispielhaft für den Freistaat Sachsen aufgezeigt. Die erste Befliegung für die BNTK wurde 1992 durchgeführt. Die Kartierung begann im Oktober 1993 und wurde 1996 abgeschlossen. Seit 2005 findet eine Aktualisierung der BNTK statt. Die Daten „bilden eine wesentliche Voraussetzung [...] um landesweite Fragestellungen und Aufgaben aus der Sicht des Natur- und Landschaftsschutzes zur Fortschreibung des Landschaftsprogramms innerhalb des Landesentwicklungsplans bearbeiten und lösen zu können (LfULG, 1994 & 2010)“ sowie „[...] auf regionaler und kommunaler Ebene als Arbeitsgrundlagen für Fachplanungen im Bereich von Naturschutz und Landschaftspflege (LfULG, 1994 & 2010)“ zu dienen. Aus der BNTK sollen Informationen zur: „Biototypenausstattung, Vorranggebiete für den Naturschutz, Potentialflächen für die Vernetzung von Biotopen, Struktur und aktuelle Nutzung der landwirtschaftlichen und forstwirtschaftlichen Flächen, Siedlungsstruktur und Gewerbenutzung im besiedelten Raum und in der freien Landschaft, Grün- und Freiflächenstrukturen in Siedlungen, luftbildsichtbare Beeinträchtigungen des Landschaftsraums (LfULG, 1994 & 2010)“ gewonnen werden. Die erste Biotopkartierung für den Freistaat Sachsen wurde in den Jahren 1991 bis 1994 durchgeführt. Durch den Anstieg der „Ansprüche an den fachlichen Naturschutz (LfULG, 2010)“ wurde jedoch eine zweite Kartierung notwendig und zwischen 1996 und 2002 durchgeführt. Eine dritte und letzte BK wurden in den Jahren 2006 bis 2008 durchgeführt. Ab 2009 wird „die selektive Biotopkartierung im Offenland in der bisherigen Form nicht mehr durchgeführt. Biotopdaten werden stattdessen im Rahmen des Grobmonitorings von FFH-Lebensraumtypen erfasst (LfULG, 2010).“

Die *Phase 1 Habitat Survey* bildet einen der Biotop- und Nutzungskartierung ähnlichen Datensatz für England, Wales und Schottland. Die erste Kartierung wurde in den 1970er Jahren durchgeführt und basiert seit 1982 auf dem gleichen hierarchischen Klassifikationssystem. Seit 1986 existiert ein der deutschen Kartieranleitungen ähnliches Handbuch, welches in den folgenden Jahren bis zu der aktuellen Version 2010 immer weiter verfeinert wurde. (JNCC, 2010)

Das Ziel der Kartierung ist wie auch bei der BNTK eine flächendeckende Erfassung aller Biototypen. Die Klassifikation basiert hierbei ebenso hauptsächlich auf der vorherrschenden Vegetation sowie der Topographie und dem Untergrund in Bereichen, welche nicht von Vegetation überwachsen sind (JNCC, 2010). Die auf der Phase 1 aufbauende *Phase 2 Habitat Survey* dient dann ähnlich der BK der detaillierten und selektiven Kartierung relevanter Flächen und Biotope (JNCC, 2010, RODWELL, 2006). Methodisch ähnelt die *Phase 1 Habitat Survey* der deutschen BK, da jede zu kartierende Fläche durch einen Kartierer vor Ort besucht wird. Als Unterstützung werden Luftbilder hinzugezogen und vor allem im urbanen Raum stark mit einbezogen. Der resultierende Maßstab der Karten beträgt 1:10000.

Als Endprodukt entstehen:

1. Karten mit den Biotopen,
2. *target notes* welche als Basis für die *Phase 2 Survey* dienen und
3. Statistiken zu allen Flächen (JNCC, 2010).

Vom Detailgrad ist die *Phase 1 Survey* zwischen der BNTK und der BK einzuordnen.

Die Erwähnung der *Phase 1 Habitat Survey* in dieser Arbeit basiert auf zwei Gründen: zum einen auf der Ähnlichkeit zur BNTK und zum anderen da durch LUCAS ET AL., 2007 und LUCAS ET AL., 2010 versucht wurde die Phase 1 Survey für Wales mittels objekt-basierter Klassifikation von Satellitendaten durchzuführen.

### 3.3 Klassifikationssysteme und Interpretierschlüssel

Die Klassifikationssysteme und die Interpretierschlüssel zur Einordnung der vor Ort real existierenden Gegebenheiten, bestehend unter anderem aus Vegetation, Boden, Topographie und der Funktion, in die jeweiligen Nomenklaturen unterscheidet sich je nach Ziel, Erhebungsmethodik und Verwendungszweck der Klassifikation. Vor allem Landbedeckungs- und Biotoptypennomenklaturen nicht vorgesehen für die Erfassung und Kartierung mittels Luft- oder Satellitenbilder besitzen Beschränkungen im Hinblick auf die Erfassbarkeit der Klassen (FULLER ET AL., 2005). So werden oftmals die Klassen anhand von Artenkompositionen, dem Untergrund, der Landnutzung oder der Funktion im Gelände definiert. Viele dieser Aspekte können aus Fernerkundungsdaten nicht eindeutig extrahiert werden (LUCAS ET AL., 2011).

Im Folgenden werden verschiedene relevante Systeme zur Kartierung von Biotoptypen vorgestellt. Die beschriebenen Klassifikationssysteme bilden die deutschlandweit am häufigsten angewendeten Systeme zur Erfassung von Biotoptypen. Vergleicht man einzelne Klassen wie in Tabelle 2 am Beispiel des Grünlandes, zeigen sich Übereinstimmungen in der Nomenklatur aber auch Abweichungen und das Fehlen ganzer Klassen in einigen der Systeme. Dies wiederum liegt begründet in den unterschiedlichen Zielen, Erhebungsmethoden und Verwendungszwecken der jeweiligen Klassifikationen. Eine über alle Systeme hinweg gültige Klassenübertragbarkeit kann deshalb nicht erreicht werden. Dies führt dazu, dass in dieser Arbeit die Biotop- und Landnutzungskartierung (BNTK) als Grundlage für die Definition des zu erreichenden Klassifikationsziels genutzt wird. Grundlage für diese Wahl ist, dass die BNTK mit dem Hintergrund der Erfassung der Biotoptypen anhand von Luftbildern entwickelt wurde. Somit besteht eine direkte thematische Verbindung zum Ziel der Arbeit, der Erfassung der Biotoptypen mittels Fernerkundungsdaten. Trotz der großen Ähnlichkeit der BNTKs der verschiedenen Länder gibt es auch innerhalb dieser bereits gewisse Unterschiede in der Nomenklatur und den zu erfassenden Klassen. Deshalb ist es notwendig die Klassen der Länder Mecklenburg-Vorpommern und Sachsen, in denen die Untersuchungsgebiete dieser Arbeit liegen, zu vereinheitlichen (Kapitel 4.5).

#### 3.3.1 Biotop- und Landnutzungskartierung

Das Klassifikationssystem mit der größten Bedeutung für die vorliegende Arbeit ist die Biotop- und Landnutzungskartierung (BNTK). Die Unterschiede der Kartierungsschlüssel zwischen CIR-Interpretation (BNTK), Geländeinterpretation (BK) und der Biotoptypenliste werden am Beispiel des Freistaates Sachsen gezeigt. Die Biotoptypenliste Sachsen (BUDER ET AL., 2004) umfasst alle Biotope der BK und erweitert diese, um einen vollständigen Überblick über alle in Sachsen vorhandenen Biotope zu erlauben. Die BNTK wiederum ist eine Generalisierung der beiden anderen Systeme, um eine Kartierung mittels der Luftbilder zu ermöglichen. Somit enthält die Biotoptypenliste den höchsten Detailgrad, die Klassen der BK sind angepasst, um die Erfassbarkeit im Gelände zu gewähren, einen hohen Detailgrad zu beinhalten und allen gesetzlichen Vorschriften im Hinblick auf den Naturschutz zu genügen. Tabelle 2 zeigt den Vergleich der Klassen für das Grünland. In der BNTK werden die Klassen Grünland und Ruderalflur zusammengefasst, während in der Biotoptypenliste und der BK das Grünland als separate Klasse erscheint. Die BNTK unterteilt diese Klasse dann weiter in unter anderem das Wirtschaftsgrünland und anschließend in Feuchtgrünland, Nassgrünland einschließlich Streuwiese. Die Biotoptypenliste unterteilt weiter in Feucht- und Nassgrünland (extensiv) und die BK in Feuchtgrünland (extensiv). Diese Klassen werden in sieben Klassen in der Biotoptypenliste und vier Klassen in der BK weiter unterteilt. Die Detailklassen der BK werden dabei teilweise mehreren Klassen der Biotoptypenliste zugeordnet.

Tabelle 2: Unterschiede der Kartierschlüssel dargestellt anhand des Grünlandes (Tabelle nach FRIETSCH &amp; SCHERFKE, 2011, Datenbasis: LFULG, 2010, LFUG, 2003, BUDER ET AL., 2004, EUNIS, 2014)

BNTK	Biotoptypenliste Sachsen	Selektive Biotopkartierung (BK)	FFH Lebensraumtypen	EUNIS
<b>4 Grünland, Ruderalflur</b>	<b>06. Grünland</b>	<b>Grünland</b>		<b>E Grasslands and lands dominated by forbs, mosses or lichens</b>
<b>41 Wirtschaftsgrünland</b>				
41400 Feuchtgrünland, Nassgrünland einschließlich Streuwiese	<b>06.01.000 Feucht- und Nassgrünland (extensiv)</b>	<b>GF Feuchtgrünland (extensiv)</b>		<b>E3 Seasonally wet and wet grasslands</b>
	06.01.100 Nasswiese	GFS Nasswiese	6440 Brenndolden-Auenwiesen 6510 Flachland-Mähwiesen	E3.4 Moist or wet eutrophic and mesotrophic grassland
	06.01.200 Pfeifengras-Wiese	GFP Pfeifengras-Wiese	6410 Pfeifengraswiesen	
	06.01.210 Pfeifengras-Wiese basenreicher Standorte		6410 Pfeifengraswiesen	
	06.01.220 Pfeifengras-Wiese bodensaurer Standorte		6410 Pfeifengraswiesen	
	06.01.300 Wechselfeuchte Stromtalwiese	GFS, GFY Nasswiese, Sonstiges Feuchtgrünland	6440 Brenndolden-Auenwiesen 6510 Flachland-Mähwiesen 6520 Berg-Mähwiesen	E3.5 Moist or wet oligotrophic grassland
	06.01.400 Seggen- und binsenreiche Feuchtweiden und Flutrasen	GFF Seggen- und binsenreiche Feuchtweiden und Flutrasen		
	06.01.500 Sonstiges artenreiches Feuchtgrünland	GFY Sonstiges Feuchtgrünland		
				E3.1 Mediterranean tall humid grassland -Mediterranean short humid grassland
				E3.2 Mediterranean short humid grassland
				E3.3 Sub-mediterranean humid meadows

### 3.3.2 Coordination of information on the environment

Das *CORINE* (*Coordination of information on the environment*) Programm der europäischen Kommission hat die drei Hauptaufgaben:

1. die für die Mitgliedsstaaten der EU relevanten Informationen über den Zustand der Umwelt zusammenzutragen,
2. die Organisation der Datensammlung auf internationaler und nationaler Ebene zu organisieren und
3. die Einheitlichkeit und Übertragbarkeit der Informationen zu gewährleisten (EC, 1995).

*CORINE land cover* (CLC) wurde 1990 (CLC, 1990) das erste Mal durchgeführt und erfasste 44 Landbedeckungsklassen in 12 Mitgliedsstaaten. Die komplette Kartierung wurde mit einem Maßstab von 1:100000 bei einer minimalen Kartiereinheit von 25 ha auf Basis von Satellitendaten (Landsat) durchgeführt (EC, 1995). National sind jedoch Vertiefungen sowohl räumlich (Maßstab) als auch thematisch (Klassenanzahl) möglich (NUTZ, 2010, MEINEL & HENNERSDORF, 2002). Der *CORINE land cover* Datensatz für Deutschland wurde 2000 beziehungsweise 2006 durch das Deutsche Fernerkundungsdatenzentrum (DFD) des Deutschen Zentrums für Luft- und Raumfahrt (DLR) aktualisiert (KEIL ET AL., 2010). Bedeckungsveränderungen kleiner als 5 ha wurden in den Aktualisierungen zusätzlich in einem Datensatz gespeichert.

Ein direkter Vergleich mit den in Tabelle 2 gezeigten Klassen ist bei den CLC Klassen jedoch nicht sinnvoll, da nur Salzwiesen, Wiesen und Weiden und Natürliches Grasland in der CLC Nomenklatur vorhanden sind und der Maßstab von 1:100000 zu grob ist. Nichtsdestotrotz bildet der *CORINE land cover* Datensatz eine hervorragende Grundlage für den Umweltschutz und Umweltmodellierung auf nationaler Ebene.

### 3.3.3 Fauna-Flora-Habitat-Richtlinie

Mit dem rechtlichen Hintergrund des Artikels 11 der Fauna-Flora-Habitat (FFH)-Richtlinie (Richtlinie 92/43/EWG DES RATES) überwachen die „Mitgliedsstaaten [...] den Erhaltungszustand der in Artikel 2 genannten Arten und Lebensräume, wobei sie die prioritären natürlichen Lebensraumtypen und die prioritären Arten besonders berücksichtigen (Europäischer Rat, 2013).“ Die FFH-Richtlinie hat zum Ziel den Rückgang beziehungsweise den Verlust von biologischer Vielfalt in den Mitgliedsstaaten der EU zu stoppen (BMU, 2005).

Methodisch im Hinblick auf die Erhebung der Daten stimmen sich die Bundesländer Deutschlands ab und haben im März 2008 sich im Rahmen der Bund-Länderarbeitsgemeinschaft Naturschutz, Landschaftspflege und Erholung (LANA) auf ein bundeseinheitliches stichprobenbasiertes Monitoringkonzept geeinigt (SACHTELEBEN & BEHRENS, 2010). Dies geschah hauptsächlich um Parallelen zu bereits laufenden „[...] Vorhaben auf EU- (Monitoring im Rahmen der Wasser-Rahmenrichtlinie), Bundes- (verschiedene F+E-Vorhaben zum Monitoring der Meeresgebiete) und Landesebene (verschiedene schon etablierte Monitoringprogramme z. B. in Sachsen, Schleswig-Holstein und Bayern [...]) (SACHTELEBEN & BEHRENS, 2010)“ zu schaffen. Weiterführende Informationen zu den Lebensraumtypen nach Anhang I der FFH-Richtlinie bieten SACHTELEBEN & BEHRENS, 2010. Die Lebensraumtypen der FFH-Richtlinie sind im Vergleich zu den anderen Klassifikationssystemen für die Grünlandklasse in Tabelle 2 dargestellt. Die Klassifikation der Lebensraumtypen ist hierbei nicht so detailliert wie die Biotoptypenliste, EUNIS und die Klassen der selektiven Biotopkartierung jedoch detaillierter als die BNTK-Klassen.

### 3.3.4 European Nature Information System

Die EUNIS (*European Nature Information System*) Daten werden durch das *European Topic Center on Biological Diversity* für die *European Environment Agency* (EEA) sowie vom *European Environmental Information Observation Network* erhoben und in einer online verfügbaren Datenbank gespeichert. Die drei Informationslevel *Species*, *Habitat types* und *Sites* sind in EUNIS enthalten. Die *habitat types* sind vergleichbar mit den in der vorliegenden Arbeit angestrebten Klassen der BNTK. EUNIS versucht mit dem entwickelten System eine harmonisierte Nomenklatur und Datensammlung für Gesamteuropa zu generieren. Definiert sind die Klassen, ähnlich wie bei BK und BNTK, anhand der vorhandenen Vegetation und Tiere als biotische Faktoren sowie den abiotischen Faktoren (DAVIES ET AL., 2004, EUNIS, 2014, NUTZ, 2010). Das *habitat types* Klassifikationssystem ist ausgelegt auf drei Ebenen, ab der vierten Ebene werden die Klassen aus anderen Klassifikationssystemen genutzt und in das EUNIS eingegliedert. Tabelle 2 zeigt einen Auszug aus dem EUNIS für den Grünland *habitat typ* im Vergleich zu BNTK, Biotoptypenliste und BK. Die erste (E) und zweite Ebene (E3) lassen sich den anderen Klassifikationssystemen leicht zuordnen. Die dritte Ebene ist bereits so stark auf die europäische Ausrichtung des Systems generalisiert, dass eine Zuordnung schwerfällt beziehungsweise teils nicht möglich ist, da Klassen in Deutschland nicht vorkommen.

### 3.4 Fernerkundung für die Biotoptypenerfassung

In den vergangenen Jahren kann ein Zuwachs von Studien im Bereich der Fernerkundung zur Erfassung von Biotoptypen verzeichnet werden. Die ersten Veröffentlichungen verwenden Luftbilder zunächst als zusätzliche Informationsebene (SUKOPP & WEILER, 1988) und anschließend finden die Luftbilder als Grundlage für die Klassifikation selbst Verwendung (KÜBLER & AMMER, 1992, COUSINS & IHSE, 1998, LESER, 2003). Mit zunehmenden Verfügbarkeit von spektral und räumlicher höher aufgelösten Satellitendaten werden auch diese zur Erfassung der Biotoptypen herangezogen (BOCK, 2003, BOCK ET AL., 2005, LUCAS ET AL., 2011, LUCAS ET AL., 2015, STRASSER & LANG, 2015). Im Folgenden werden Untersuchungen basierend auf unterschiedlichen Fernerkundungsdaten näher beleuchtet.

#### 3.4.1 Optische Satellitenbilder

Biotoptypenkartierungen auf der Grundlage von optischen Fernerkundungsdaten werden seit den 1990ern durchgeführt und seither kontinuierlich weiterentwickelt (BOCK, 2003).

STRASSER & LANG, 2015 verwenden eine WorldView-2 Szene für die Klassifikation von Auwald-Biotopen mittels einer hierarchisch aufgebauten, objekt-basierten Methode. Die Klassifikation beruht auf sechs Ebenen bei denen von zunächst Baumarten (anhand einzelner Baumkronen) bis hin zu den komplexeren Waldbiotopen, definiert durch das EUNIS-Klassifikationsschema, klassifiziert wird. Für die grundlegende Klassifikation der Baumkronen wird eine überwachte *Bayesian* Klassifikation der spektralen Objekteigenschaften verwendet. Die weiterführende Klassifikation verwendet dann die Baumobjekte um auf weiteren, gröberen Segmentierungsebenen die Baumbestände anhand von relationalen und geometrischen Objekteigenschaften, der EUNIS-Regeln folgend, auszuweisen. Die Gesamtgenauigkeit der Baumartenklassifikation erreichte einen Wert von 86.93% und einen Kappa-Wert von 0.84. Die flächenmäßige Abweichung zwischen der finalen Klassifikation der Biotope und der Referenzkarte liegt bei 11.7 %, was die Autoren als eine Genauigkeit von 88.3 % interpretieren. Die Autoren betonen, dass der Ansatz durch das klare Folgen des EUNIS-Regelwerks sehr robust und übertragbar ist. Den wichtigsten Punkt in der Methode sehen die Autoren in der korrekten Klassifikation der Baumarten, da diese das finale Ergebnis maßgeblich beeinflusst.

Als zukünftige Verbesserungen schlagen die Autoren hier die folgenden Punkte vor:

1. eine verbesserte Vor-prozessierung (Atmosphärenkorrektur) und die Verwendung von spektralen Bibliotheken für die Baumarten,
2. genauere in-situ Daten,
3. Erweiterung der Datenbasis durch multi-saisonale Daten, die Verwendung von Hyperspektraldaten oder LiDAR-Daten und
4. die Verwendung von anderen Klassifikationsmethoden wie *support-vector-machine* (SVM) oder *Random Forest* (RF).

LUCAS ET AL., 2011 veröffentlichen eine Studie zur Kartierung von Biotoptypen unter Verwendung von Satellitendaten für ganz Wales. Hintergrund der Untersuchung ist ein aufgrund der signifikanten Veränderungen der semi-natürlichen Vegetation notwendig gewordenes Update der *Phase 1 Survey* (P1S). Die Veränderungen seit der Erhebung der P1S haben ihre Ursachen in der Anpassung der Aktivitäten, Herangehensweisen und Vorschriften in den Bereichen der Land- und Forstwirtschaft in Wales sowie dem Klimawandel und den damit einhergehenden Anpassungsstrategien (BERRY ET AL., 2002, LUCAS ET AL., 2011). Die Veröffentlichung basiert auf einer vorangegangenen Veröffentlichung der Autoren (LUCAS ET AL., 2007). In LUCAS ET AL., 2007 wurden basierend auf Zeitserien des Landsat TM/ETM vom Juli 2001 und März, April und September 2002 für ein Untersuchungsgebiet in Wales (Berwyn Mountains) anhand eines objekt- und regelbasierten Algorithmus Biotoptypen definiert durch den *Biodiversity Action Plan* (BAP) (UKBAP, 2007, UKBAP, 2010, JNCC, 2010) kartiert. Als Ergebnis der Studie von LUCAS ET AL., 2007 wurden Biotoptypen und landwirtschaftliche Landbedeckungsklassen



(insgesamt 11 Klassen mit einer Gesamtgenauigkeit von 84.9 %) mit einem ähnlichen beziehungsweise teilweise höherem Detailgrad im Vergleich zur P1S erreicht. Lucas et al., 2011 setzen ihre vorangegangenen Untersuchungen fort und fügen dieser weitere Klassen hinzu und dehnen das Untersuchungsgebiet auf das gesamte Wales aus. In der als Referenz und als Klassifikationsziel vorliegenden P1S werden 10 Hauptklassen und 103 Detailklassen definiert. Die Autoren weisen an dieser Stelle darauf hin, dass die Detailklassen nicht unbedingt direkt aus den Fernerkundungsdaten extrahierbar sind. Dies ist bedingt zum einen durch die spektralen Variationen hervorgerufen durch das regionale Klima, der Jahreszeit der Datenakquise, der Topographie und der regional unterschiedlichen Phänologie und zum anderen durch die Definition der Biotoptypen (z.B. Biotoptypen bestehend aus verschiedenen spektral unterschiedlichen Vegetationsspezies zusammengefasst zu einem Biotyp). Als Lösungsansatz für das erste Problem wurde Wales in homogene biogeographischen Regionen unterteilt und als Lösungsansatz für das zweite Problem wurden die Klassen nicht direkt extrahiert, sondern als einzelne Bestandteile der Klassen, welche anschließend in der Zielklasse zusammengeführt wurden. Für Wales wurden 15 biogeographischen Regionen basierend auf bioklimatischen Karten unter Berücksichtigung der Topographie, der Verteilung der Biotoptypen und weiteren Umwelteinflüssen definiert. Aus diesen Regionen wurden 16 Projekte abhängig von der Datenlage (eine Region musste geteilt werden) mit 42 Teilentwicklungsgebieten erzeugt. Als Daten dienten 14 SPOT-5 *High Resolution Geometric* (HRG) Szenen mit einer räumlichen Auflösung von 10 m und spektralen Informationen aus dem sichtbaren, NIR und SWIR Bereich, ein Terra-1 Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER, räumliche Auflösung 15–30 m) Mosaik aus zwei Szenen und vier Szenen des *Indian Remote Sensing Satellite* (IRS) LISS-3 (räumliche Auflösung 24 m). Als zusätzliche Daten dienten CIR-Luftbilder mit einer räumlichen Auflösung von 0.4 m für Wales aus den Jahren 2001 und 2006, ein digitales Geländemodell (DGM) (*NextMap Intermap*) mit einer räumlichen Auflösung von 5 m, ein Vektordatensatz der Feldgrenzen (*Land Parcel Information Service* (LPIS)), ein Vektordatensatz der Wasserflächen und urbanen Gebiete (*OS Mastermap*) sowie einer Maske der Küstenlinie. Als Referenzkarten wurden die Phase 1 und 2 Surveys verwendet. Die SPOT-5 Daten dienten als Basis der Untersuchung und konnten für 15 der 16 Teilprojekte akquiriert werden. Die für die phänologische Analyse wichtigen Frühjahrsaufnahmen waren für 14 Regionen verfügbar, die beiden anderen Regionen verfügten über 2 Szenen im Juli respektive über jeweils eine Szene im Juli und im September. Die Daten wurden ortho-rektifiziert, radiometrisch-kalibriert sowie atmosphärisch (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH)) und topographisch normalisiert (ATCOR 3). Anschließend wurden für die Regionen naturnahe Objekte mittels einer multi-resolution Segmentierung erzeugt. Anschließend wurden zwei weitere Segmentierungsebenen erzeugt, eine grobe Segmentierung mit den Grenzen des LPIS-Datensatzes und eine sehr feine Segmentierung mit Objekten von nur wenigen Pixeln. Die Klassifikation erfolgte regel- und Expertenwissen-basiert. Als Merkmale wurden die Reflexionen, Bandratio und -differenzen, Vegetationsindices, spektral-räumliche Beziehungen (z.B. spektrale, relative Differenz zu Nachbarpixel) und die saisonale Varianz. Hierbei wurden 35 teils multi-temporale Merkmale basierend auf den spektralen Informationen erzeugt. Die anschließende Klassifikation erfolgte in mehreren Schritten. Zu Beginn wurden eindeutige Klassen (z.B. Wasserflächen) direkt großflächigen Segmenten basierend auf SPOT Daten zugewiesen. Die Detailklassen wurden anschließend anhand von Expertenwissen auf einer feineren Segmentierungsebene mittels fuzzy membership zugeordnet. Hierbei wurden jeweils die drei Klassen mit den höchsten Objektanteilen berücksichtigt. Dies bedingte eine Genauigkeitsanalyse abweichend von der traditionellen Methode der Konfusionsmatrix. Eine Genauigkeitsanalyse anhand der Kategorien: *Disagree* – Die zwei Karten zeigen unterschiedliche Biotoptypenklassen, *Possible* – Die kartierte Klasse könnte aus der Referenzklasse hervorgegangen sein (Veränderung), *Plausible* – Die Karten zeigen sehr ähnliche Biotoptypen, *Agree* – Die Karten zeigen die gleiche Klasse, wurde gewählt. Nichtsdestotrotz werden abschließend die anhand des Expertenwissens zugeordneten Klassen räumlich, prozentual verglichen. Der Vergleich zeigt generell eine Genauigkeit von über 70 % mit zahlreichen Klassen über 80 % (z.B. Nadel- und Laubwald, intensiv genutztes beziehungsweise Feucht-Grünland, Wasserflächen und landwirtschaftliche Flächen). Niedrigere Genauigkeiten wurden bei Gebüsch (34 %) sowie extensiv genutztem Grünland (39 %) erzielt.



Die Gesamtgenauigkeit lag bei 80.7 %. Hierbei konnte für zwei Teilprojekte eine höhere Genauigkeit als bei der originalen P1S erzielt werden. In der Diskussion und Zusammenfassung unterscheiden die Autoren zunächst zwischen dem verwendeten objekt-orientierten Ansatz und einem objekt-basierten Ansatz. Der gewählte objekt-orientierte Ansatz besteht nicht nur wie der objekt-basierte Ansatz aus den Schritten der Objektgenerierung und Klassifikation, sondern fügt den zusätzlichen Schritt der Objektmodifikation im Laufe des Klassifikationsprozesses hinzu. Somit werden durch die Veränderung des Basisobjektes die finalen Klassifikationseinheiten generiert. Die vorliegende Studie bildet somit die erste Umsetzung einer objekt-orientierten, regel-basierten Detailklassifikation von Biotoptyp- und Landnutzungsklassen auf nationaler Ebene. Die angesprochenen Regeln wurden mittels Expertenwissen aufgebaut und erlaubten die Verwendung eines einzigen Regelwerkes auf 16 Projekten mit wiederum 42 Teilprojekten für die Klassifikation der Flachland-, Hochland- und Küstenregionen. Mittels hauptsächlich spektraler, jedoch auch topographischer und kontextueller Informationen konnten 105 Klassen kartiert werden. LUCAS ET AL., 2011 weisen jedoch auch darauf hin, dass leichte Anpassungen der Schwellwerte in den unterschiedlichen Projekten notwendig waren, um vor allem phänologische Effekte ausgleichen zu können. Die Aufnahme einer Vielzahl von Daten über den Jahresgang hinweg und die Abdeckung der phänologischen Phasen führte auf der anderen Seite jedoch auch zu einer besseren Abtrennung der Biotoptyp- und Landnutzungsklassen. Aufnahmen zwischen März und Juli waren besonders geeignet, Aufnahmen vor Februar oder nach November wurden als nur begrenzt nützlich eingestuft. Abschließend schätzen LUCAS ET AL., 2011 die folgenden drei Punkte als essentiell für den erreichten hohen Detailgrad der Klassifikation ein:

1. die Verwendung multi-temporalen, sehr hochauflösender optischer Daten sowie Vektordaten (LPIS) und der damit verbundenen Segmentierung in naturnahe und direkt mit der Landschaft verknüpfbare Objekte wie z.B. Hecken und Felder,
2. die Gewährleistung der Vergleichbarkeit der Daten und extrahierten Merkmale basierend auf sehr genauer Orthorektifizierung, Atmosphärenkorrektur und topographischer Normalisierung,
3. Die Anwendung einer logischen Abfolge von wissensbasierten Regeln definiert je nach Klasse mittels Schwellwerten, booleschen Operatoren und/oder *fuzzy membership*.

Somit bildet dieser Ansatz die erste umfassende Kartierung von Biotoptypen- und Landnutzungsklassen auf nationaler Ebene. Die zugrundeliegenden Daten wurden zwischen 2003-2006 aufgezeichnet. LUCAS ET AL., 2011 weisen jedoch ausdrücklich darauf hin, dass das System auf neues Wissen und neue Daten angepasst werden kann und somit ein immer wieder anpassbarer Ansatz für die Entwicklung und Implementierung einer satelliten-gestützten Überwachung für Wales und auch andere Länder entstehen kann.

LUCAS ET AL., 2015 entwickeln ihren im Vorangegangenen vorgestellten Ansatz weiter zum *Earth Observation Data for Habitat Monitoring (EODHaM)* System. Das System basiert auf dem von der *Food and Agriculture Organization (FAO)* entwickelten *Land Cover Classification System (LCCS)* (DI GREGORIO & JANSEN, 2005). Die so erhaltenen Informationen werden dann den Biotoptypen, hier *General Habitat Categories (GHCs)*, zugewiesen. Die Methode verwendet einen objekt-basierten Klassifikationsansatz und wird anhand von vier grundlegenden Schritten durchgeführt:

1. Datenvorprozessierung (Orthorektifizierung, radiometrische Korrektur, Atmosphärenkorrektur und topographische Korrektur),
2. spektrale Merkmalsextraktion, Segmentierung und Klassifikation auf der Ebene 2 der LCCS,
3. Klassifikation in die höheren Ebenen der LCCS anhand von Expertenwissen und
4. Übertragung der erhaltenen Klassen in die Zielbiotoptypen

Ein weiterer Schritt für die Validierung und die Veränderungsanalyse kann optional hinzugefügt werden. Der verwendete Prozess ist teil-automatisiert und verwendet *open-source* Produkte wie die *GIS Library (RSGISLib) Software*, die *Geospatial Data Abstraction Library (GDAL)*, die *ORFEO Toolbox*, XML, PYTHON und das KEA Dateiformat. Als optimale Eingangsdaten beschreiben die Autoren WorldView-2 oder hyperspektrale optische Daten mit mehreren Abdeckungen pro Jahr. Darüber hinaus ist es möglich weitere Datenquellen wie thematische Daten oder LiDAR- oder SAR-Daten dem System

hinzuzufügen. LUCAS ET AL., 2015 geben keine direkten Validationsergebnisse an, sondern verweisen auf Klassifikation innerhalb des Forschungsprojektes *BIOdiversity multi-SOource monitoring System: from Space to Species* (BIO\_SOS) anhand des EODHaM Systems in Wales, Holland, Italien, Griechenland, Portugal und Indien. Generell betonen die Autoren, dass die Genauigkeit von der Qualität und räumlicher sowie spektraler Auflösung der Eingangsdaten sowie der betrachteten Klasse abhängt. Als Beispiel gehen sie von sehr hohen Klassifikationsgenauigkeiten (> 97 %) im Bereich von homogenen Klassen wie Nadelwaldplantagen und offenem Wasser aber geringen Klassifikationsgenauigkeiten (~ 30 %) bei komplexen und heterogenen Klassen wie Moosen in Wales oder mehrjährigen, aquatischen Gräsern in Italien aus.

BOCK ET AL., 2005 verwenden Landsat TM 4/5, Landsat ETM+, HRSC (inklusive DSM) und ASTER Daten zur Kartierung von Biotoptypen auf lokaler und regionaler Ebene in einem Untersuchungsgebiet in Schleswig-Holstein sowie Quickbird Daten zur Kartierung von Biotoptypen in Wye Downs (England). Als weitere Klassifikationsgrundlage lassen die Autoren Boden-, Amtliches Topographisch-Kartographisches Informationssystem (ATKIS)- und (Biotop- und Landnutzungskartierung) BNTK-Karten in die Bearbeitung mit einfließen. Für das Untersuchungsgebiet in Schleswig-Holstein wurden Referenzdaten im Gelände in den Jahren 2002 (Juli) und 2003 (Juli), für das Untersuchungsgebiet Wye Downs im Jahr 2003 (Mai) erhoben. Ziel der Untersuchung war es mittels der vorhandenen Fernerkundungsdaten sowohl einen regionalen als auch einen lokalen Klassifikationsansatz zu entwickeln, der regional zehn Klassen, basierend auf der ersten Ebene des EUNIS-Systems, und lokal acht Detailklassen basierend auf der zweiten und dritten Ebene des EUNIS-Systems, umfasst. Methodisch verwenden BOCK ET AL., 2005 einen objekt- und regelbasierte Ansatz unter Anwendung von spektralen und texturalen Merkmalen, des NDVI und Objekthöheninformationen (Schleswig-Holstein). Darüber hinaus lassen die Autoren die Bodenkarten in die Segmentierung, die ATKIS-Daten zur Ableitung der Verkehrsinfrastruktur und die BNTK-Daten als Objektgrenzen direkt in die Klassifikation mit einfließen. Für die Ableitung der zehn Zielklassen auf regionaler Ebene werden multi-temporale, spektrale und Objekthöheninformationen verwendet. Auf der lokalen Ebene im Wye Downs Untersuchungsgebiet werden weitere Informationen z.B. GLCM-Textur aus den verwendeten Quickbird-Daten generiert. Als Methode zur Merkmalsauswahl wird eine Korrelationsanalyse verwendet. Anschließend werden auf mehreren Ebenen objekt-basiert die acht Zielklassen unter teils manuellen Verfeinerungen ausgewiesen. Als Ergebnis wurden für die regionale Klassifikation in Schleswig-Holstein mit zehn Klassen eine Gesamtgenauigkeit von 86.19% und ein Kappa von 0.8 erreicht. Für das lokale Testgebiet Wye Downs mit acht Detailklassen wurden eine Gesamtgenauigkeit von 80.7% und ein Kappa von 0.7513 erreicht. Als herausragende Merkmalsgruppe für die lokale Klassifikation nennen die Autoren die GLCM Textur. Eine Übertragbarkeit auf einen anderen Zeitraum oder ein weiteres Untersuchungsgebiet konnte aufgrund fehlender Referenzdaten nicht durchgeführt werden. Die Autoren fassen zusammen, dass ein objekt-basierter Ansatz unter Verwendung von hochaufgelösten Fernerkundungsdaten im regionalen Bereich und einer geringen thematischen Vielfalt sowie für sehr hochaufgelöste Fernerkundungsdaten und einer hohen thematischen Vielfalt sehr gute Ergebnisse liefern kann. Darüber hinaus kann durch die gezeigte Methode eine vergleichbare Gesamtgenauigkeit erreicht werden wie durch traditionelle Kartiermethoden, bei gleichzeitig erhöhtem räumlichen Detail und der Möglichkeit der Erkennung von Variationen innerhalb eines Biotoptyps. In der Möglichkeit der Integration von externen Informationen (ATKIS, BNTK, Bodendaten) sehen die Autoren einen weiteren wesentlichen Vorteil.

Weitere Untersuchungen basierend auf multispektralen Daten liefern z.B. BERHANE ET AL., 2018, FEILHAUER ET AL., 2014, LABA ET AL., 2010, MACK ET AL., 2016, SESNIE ET AL., 2008 und VARELA ET AL., 2008.

### 3.4.2 Color-Infrarot- und Hyperspektrale-Luftbilder

In den späten 70iger und frühen 80iger Jahren des vergangenen Jahrhunderts fanden die ersten Luftbilder Anwendung in der Biotoptypenkartierung (SUKOPP & WEILER, 1988). Zunächst lediglich eingesetzt zur Auswahl von geeigneten Begehungsgebieten und zur Unterstützung der manuellen Kartierung im Gelände (SUKOPP & WEILER, 1988) gewannen die Luftbilder zunehmend an Bedeutung und dienten vor allem in den 1990er Jahren als Grundlage für die zunächst manuelle flächendeckende Erfassung (LFUG, 2004, LUNG, 1998) von Biotoptypen. Allerdings finden Color-Infrarot- (CIR) Luftbilder in den letzten Jahren kaum noch Anwendung und werden von den hyperspektralen Luftbildauswertungen abgelöst. Untersuchungen zur Biotoptypenkartierung anhand von CIR Luftbildern sind unter anderem COUSINS & IHSE, 1998, ERIKSON, 2004 und EHLERS ET AL., 2003.

COUSINS & IHSE, 1998 verwenden CIR Luftbilder für die Kartierung von Biotopen in Südschweden. Ausgewählt wurden vier von den physikalischen Gegebenheiten sehr unterschiedliche Testgebiete. Ziel der Arbeit war es auf Basis der CIR Luftbilder eine Methode zur Kartierung von Landschaftselementen und Biotopen, welche eine übergeordnete Rolle für die Biodiversität spielen, zu entwickeln. Der Schwerpunkt des Artikels liegt auf der Entwicklung eines Klassifikationssystems. Hierbei wird unterschieden zwischen flächenhaften, linienförmigen und punktförmigen Landschaftselementen und Biotopen. Auf der Grundlage des Klassifikationssystems werden die Klassen mittels einer visuellen Interpretation zugewiesen. Bei der Genauigkeitsanalyse wird für die acht Klassen der Untergruppe (Nadelwald, Mischwald, Laubwald, Ackerland, Grünland, aufgeforstetes Ackerland, urbane Gebiete und Wasserflächen) eine Gesamtgenauigkeit von 97% erreicht. COUSINS & IHSE, 1998 merken jedoch an, dass das Ergebnis stark abhängig ist von der Qualität der Luftbilder (ausreichender Kontrast, Aufnahmezeitpunkt und Zeit zwischen Aufnahme und Interpretation) sowie dem Interpreten. Darüber hinaus schätzen die Autoren den Aufwand für die Interpretation der Landschaftselemente und Vegetationstypen auf etwa 1.4-2.8 km<sup>2</sup>/h (IHSE, 1978, COUSINS & IHSE, 1998) eine Feldbegehung kann etwa 2 km<sup>2</sup> pro Tag kartieren (BORG, 1977, COUSINS & IHSE, 1998).

Eine weitere Anwendung im Bereich der Biotoptypenklassifikation, im Speziellen zur Baumartenklassifikation mittels CIR Luftbildern stellt ERIKSON, 2004 vor. Verwendet werden CIR Luftbilder über einer Fläche von 5 x 5 km im Bereich von Sundsvall (Schweden) vom 10. August 1995 mit drei spektralen Kanälen zwischen 500 und 900 nm und einer räumlichen Auflösung von 3 cm. Als Übertragbarkeitsgebiet für die entwickelte Methode dienen Luftbilder vom 7. Juli 1999 im Bereich von Tönnersjöheden (Schweden) mit den gleichen spektralen Eigenschaften, jedoch einer leicht reduzierten räumlichen Auflösung von 10 cm. Ziel der Arbeit ist es Baumkronen zu identifizieren und diese den vier vorherrschenden Baumarten (Birke, Espe, Kiefer und Fichte) zuzuordnen. Der Autor verwendet zunächst einen objekt-basierten Ansatz um die Baumkronen zu identifizieren, anschließend entwickelt er für jede Baumart Regeln basierend auf spektralen, relationalen und geometrischen Merkmalen. Als Gesamtgenauigkeit (*Overall Accuracy*) für die vier Baumarten erhält der Autor 76,7 % für das Entwicklungstestgebiet und 70,9 % für das Übertragungsgebiet. Der Autor weist jedoch auf einige Probleme seiner Methode hin. Es werden feste Regeln und Schwellwerte verwendet, welche auf die vorliegenden Luftbilder angepasst sind. Probleme bei der Übertragung der Methoden können hierbei vor allem aus einem veränderten Sonnenazimut und veränderter Beleuchtung (andere Jahres- oder Tageszeit) sowie der Abweichung vom Nadir bei der Aufnahme resultieren. Darüber hinaus macht der Autor deutlich, dass die Segmentierung der Baumkronen ein entscheidender Punkt ist und die räumliche Auflösung hierfür bereitgestellt werden muss. Insgesamt liefert die vorgestellte Methode ein gutes Ergebnis für die vorliegenden Daten, muss jedoch bei einem Transfer auf andere Daten und Testgebiete angepasst werden.

EHLERS ET AL., 2003 verwenden *High Resolution Stereo Camera* (HRSC)-A Daten mit einer räumlichen Auflösung von 15 cm und fünf spektralen Bändern (panchromatisch 585-765 nm, blau 395-485 nm, grün 485-575 nm, rot 730-770 nm und nahem infrarot 920-1020 nm) zur Biotoptypenkartierung in drei

kleinen Untersuchungsgebieten an der Elbe. Ebenso wie bei TANSEY ET AL., 2009 (Kapitel 3.4.5) wurde auch hier ein digitales Oberflächenmodell (DOM) aus dem panchromatischen Kanal generiert. Hintergrund der Untersuchung ist die potenzielle Veränderung der vorhandenen Biotoptypen aufgrund einer vorangegangenen Erweiterung der Fahrrinne in der Elbe. Durch das Design der HRSC-A für die Anwendung auf dem Mars entsprechen die spektralen Bänder nicht den üblichen spektralen Kanälen wie sie z.B. Landsat besitzt. Dies führt dazu, dass der HRSC-A keinen roten Kanal besitzt. Um die für die Vegetationskartierung wertvollen Informationen aus dem roten Wellenlängenbereich nutzen zu können entschieden sich die Autoren aus den panchromatischen und den nahen infraroten Bändern ein synthetisches rotes Band zu berechnen. Die Methodik zur Ausweisung der vorhandenen Biotope beruht auf einer drei Ebenen Hierarchie. Unter Verwendung der spektralen Bänder inklusive des synthetischen roten, sowie der Objekthöhen und Texturmaßen werden in der ersten Ebene die vier Klassen „Nicht-Vegetation / spärliche Vegetation“, „Schatten“, „niedrige Vegetation < 12 m“ und „hohe Vegetation > 12 m“ ausgewiesen. In der zweiten Ebene werden die Klassen in 21 Unterklassen weiter verfeinert, die Klasse „Nicht-Vegetation / spärliche Vegetation“ anhand eines ISODATA Algorithmus, die Klassen „niedrige Vegetation < 12 m“ und „hohe Vegetation > 12 m“ anhand eines *Maximum-Likelihood* Klassifikators. In der dritten Ebene werden die aus der zweiten Ebene resultierenden Klassifikationsergebnisse in einem geographischen Informationssystem (GIS) in einer Ergebnisebene zusammengeführt. In diesem Schritt werden für die einzelnen Biotope minimale Flächen und Nachbarschaftsbeziehungen definiert und die Schatten aus der Klassifikation eliminiert. Zur Validierung wurde zum einen ein visueller Vergleich der Ergebnisse mit einer Referenzkarte beruhend auf der BNTK-Kartierung des Landes durchgeführt und zum anderen eine auf 200 Referenzpunkten beruhende Genauigkeitsanalyse. Die visuelle Genauigkeitsanalyse ergab, dass die auf den HRSC-A Daten beruhende Klassifikation deutlich mehr Details enthält als die Referenzkarte und die Referenzkarte somit nur bedingt für eine Validierung geeignet ist. Die auf den Referenzpunkten beruhende Genauigkeitsanalyse ergab für die in diesem Untersuchungsgebiet am relevantesten Klassen (Reedflächen und Weiden) eine Gesamtgenauigkeit von 95 %. EHLERS ET AL., 2003 zeigen in ihrer Veröffentlichung klar das Potenzial von Luftbildern zur Kartierung von Biotoptypen in einem lokalen Testgebiet. Sie weisen ausdrücklich darauf hin, dass die Objekthöhen und die im dritten Schritt der Klassifikation durchgeführten relationalen und geometrischen Abfragen entscheidend zur hohen Klassifikationsgenauigkeit beitragen.

Auch die staatlichen Biotoptypenkartierungen nutzen Luftbilder zur Ableitung der Klassen. Verwendet wird hierbei ein dem Geländeschlüssel gegenüber veränderter Klassifizierungsschlüssel (Tabelle 2) (FRIETSCH & SCHERFKE, 2011). Die staatlichen Stellen des Landes Sachsen schätzen den Nutzen und die Verwendbarkeit der CIR-Luftbilder für die Biotoptypenkartierung und –Bewertung differenziert ein. Im Konkreten werden vier Punkte mit direktem Bezug zu den Biotoptypen genannt. Diese sind: 1) „Anwendung beim 2. Durchgang der selektiven Biotopkartierung bei der Erfassung und Darstellung der Biotope sowie Optimierung der Kartierungsarbeit“, 2) „Biotopvernetzungsplanung (systematische Aufbereitung von Biotoptypen und Identifikation potentieller Vernetzungsstrukturen)“, 3) „Flächenberechnungen/-bilanzierungen über alle Biotoptypen und Landnutzungsformen für ausgewählte Landschaftsausschnitte, Verwaltungseinheiten, Naturräume etc.“ und 4) „Darstellung ausgewählter Biotoptypen in verschiedenen Maßstäben“ (FRIETSCH & SCHERFKE, 2011).

Auch im Zuge der PIS Erhebung in Großbritannien werden Luftbilder verwendet. Jedoch wird auch hier gleich zu Beginn betont, dass Luftbilder kein Ersatz für eine umfassende Feldbegehung zur Erhebung der natürlichen und semi-natürlichen Vegetation beziehungsweise Biotoptypen sind (JNCC, 2010). Vorteile durch die Verwendung von CIR-Luftbildern sehen die Autoren in: „die Gebiete der Begehung im Vorhinein einsehen zu können“, „die Möglichkeit schwer zugängliche Gebiete zu kartieren indem man sie mit benachbarten, in einer Begehung kartierten Gebieten vergleicht“, „Gebiete die einer besonderen Beachtung bedürfen anhand der Luftbilder auszuwählen“, „Grenzen von klar definierten Biotoptypen festzulegen beziehungsweise Grenzen zwischen unterschiedlichen Biotoptypen ziehen, welche bis dahin noch nicht inkludiert waren“, „Auswahl von Enklaven z.B.

Nadelwaldflächen in Laubwäldern und vice-versa“, „Auswahl von unterentwickelten urbanen Flächen und die Überprüfung der Aktualität des Infrastrukturnetzes in den vorhandenen Karten“ und „langfristige Beobachtung in der Verteilung und Häufigkeit von Biotoptypen“ (JNCC, 2010). Probleme entstehen bei Biotoptypen welche nicht klar in Luftbildern trennbar sind, dies gilt vor allem bei Grünlandklassen, kleinräumigen beziehungsweise ungewöhnlichen Biotoptypen oder Bereichen in denen eine bestimmte Funktion besteht (z.B. Quellgebiet). Darüber hinaus ist die Eignung der Luftbilder abhängig von der Qualität, dem Alter, der Skala und dem Aufnahmezeitpunkt (Jahres- und Tageszeit).

Zusammenfassend kann über die CIR-Luftbilder gesagt werden, dass eine operationelle Anwendung durch Interpretation in der Biotoptypenkartierung bis zu einem bestimmten Grad möglich ist. Limitierungen bestehen bei Klassen, welche nicht in den Bildern spektral, textural und relational trennbar sind, dies bezieht sich vor allem auf Grünlandklassen, aber z.B. auch auf Baum- und Heckenvegetation, welche nur anhand von Höheninformationen trennbar sind. Darüber hinaus können Klassen auf Speziesebene (*Alopecurus pratensis*, *Poa annua*, *Polygonum aviculare* für Intensivgrünland auf Mineralstandorten zur Unterscheidung von anderem Intensivgrünland), Funktionsklassen (Quellbereiche bei Fließgewässern) sowie Attributklasse (nährstoffarm beziehungsweise nährstoffreich bei Stehenden Gewässer) aus CIR-Luftbildern nicht unterschieden werden. Eine Operationalisierung für lokale Bereiche mit klar definierten Klassen (EHLERS ET AL., 2003) oder regionale Bereiche mit wenigen Klassen (ERIKSON, 2004) ist jedoch möglich. Die Luftbilder dienen somit meist als informative Grundlage für tiefergehende Untersuchungen und werden mit anderen Daten wie Vektordaten der Ämter oder Höhendaten zusammen genutzt.

In Die hyperspektralen Daten liefern aufgrund der Vielzahl der spektralen Kanäle eine sehr gute Grundlage um Biotoptypen abzuleiten. Untersuchungen anhand von hyperspektralen Daten für die Biotoptypenableitung findet kontinuierlich seit über 15 Jahren statt. Untersuchungen in diesem Bereich sind unter anderem ASPINALL, 2002, BACHMANN ET AL., 2003, FEILHAUER ET AL., 2014, HAEST ET AL., 2017, LECKIE ET AL., 2003, SEGL ET AL., 2003, HILL & THOMSON 2005, BELLUCO ET AL. 2006, PIGNATTI ET AL., 2009, HUFKENS ET AL., 2010, SCHMIDT ET AL, 2017A und SKOWRONEK ET AL., 2017.

### 3.4.3 Aktive Fernerkundung

Die für die Arbeit relevanten aktiven Systeme umfassen das *synthetic aperture radar* (SAR) und das *Light detection and ranging* (LiDAR). LiDAR bildet die Grundlage für das verwendete Oberflächenmodell der Testgebiete, wird jedoch auch ohne weitere Informationen für die Klassifikation verwendet. Beispiele für die Klassifikation von Biotoptypen ausschließlich mit LiDAR bilden WEDDING ET AL., 2008 im Bereich der litoralen Gewässerfernerkundung sowie ZLINSZKY ET AL., 2014, welche ausschließlich LiDAR-Daten für die Klassifikation von Graslandbiotoptypen verwenden.

Im Bereich der rein SAR-basierten Ansätze zur detaillierten Biotoptypen- und Landnutzungskartierung gibt es bis dato weniger Veröffentlichungen im Vergleich zu den Veröffentlichungen im Bereich der passiven Fernerkundung. Viele Artikel beschäftigen sich mit der multi-temporalen Feldfruchtkartierung und einige mit der Landnutzungs- beziehungsweise Landbedeckungsklassifikation. Veröffentlichungen mit einem thematischen Überlapp zur Biotoptypenkartierung werden im Folgenden vorgestellt.

BARGIEL, 2013 verwendet sechs TerraSAR-X Szenen aufgenommen zwischen April und Oktober für die Klassifikation von fünf Biotoptypen (Blühstreifen, Grasland, Büschen, Ruderalflur und Baumvegetation). Für die Klassifikation verwendet der Autor als Eingangsdaten die SAR-Rückstreuung und daraus abgeleitete Texturmaße. Methodisch vergleicht BARGIEL, 2013 einen pixel-basierten *Maximum-Likelihood-Classificator* (MLC) und einen pixel-basierten *Random Forest* (RF) Klassifikator im Hinblick auf die resultierende Klassifikationsgenauigkeit. Die Klassifikation wird zum einen ohne

Berücksichtigung der Texturmaße und zum anderen mit Berücksichtigung der Texturmaße durchgeführt. Die Ergebnisse variieren stark je nach Klasse. So erreicht der MLC ohne Textur eine Genauigkeit von 75 % bei der Klasse der Blühstreifen. Dagegen werden nur 43.7 % (RF ohne Textur) bei den Ruderalfluren erreicht. Generell zeigt sich kein klarer Trend welche Datengrundlage (mit oder ohne Textur) und welcher Klassifikator überlegen ist. Bei den Blühstreifen erreicht der MLC ohne Textur die höchste (75 %) und der ML mit Textur die niedrigste (68.1 %) Klassifikationsgenauigkeit. Bei der Graslandklasse, den Ruderalfluren und der Baumklasse erreicht der RF (mit Textur die höchste (75.8 % / 57 % / 68.5 %) und der MLC ohne Textur die niedrigste (70.7 % / 43.7 % / 60.6 %) Klassifikationsgenauigkeit. Bei der Gebüschklasse erreicht der MLC mit Textur die höchste (63.7 %) und der RF ohne Textur die niedrigste (46.8 %) Klassifikationsgenauigkeit. Generell zeigen die aus den Satellitendaten abgeleiteten Biotoptypen einen sehr guten Überlapp mit den flächigen Referenzdaten. Durch die Verwendung einer objekt-basierten Methode oder Nachbearbeitung der Ergebnisse mittels z.B. räumlicher Mehrheitsfilter ließen sich die erzielten Genauigkeiten ohne Änderung des eigentlichen Ansatzes weiter steigern (BARGIEL, 2013).

QI ET AL., 2012 implementieren einen "vier Komponenten-Ansatz" zur Klassifikation von sieben Landbedeckungs- beziehungsweise Landnutzungsklassen:

1. Wasser,
2. Wald,
3. Bananenplantagen,
4. Urbane Gebiete,
5. Brachland/Flächen mit geringer Vegetationsbedeckung,
6. Landwirtschaftliche Flächen/Natürliche Vegetation und
7. Grasland auf Basis von RADARSAT-2-Daten (PolSAR).

Die für die Methode namensgebenden vier Komponenten sind:

1. polarimetrische Dekomposition,
2. Pol-SAR Interferometrie,
3. objekt-basierte Bildverarbeitung und
4. ein *Decision Tree* Klassifikator.

Darüber hinaus vergleichen die Autoren die angedachte Methode mit einer pixel-basierten, überwachten Wishart-Klassifikation. Die Gesamtgenauigkeit der Methode geben die Autoren mit 86.64% an, während die Wishart-Klassifikation lediglich 69.66% erreicht. Bei der Untersuchung der Eingangskomponenten stellen QI ET AL., 2012 fest, dass die polarimetrischen Informationen einen signifikanten Anteil an der Trennung der Vegetationstypen untereinander und der Vegetation und der urbanen Gebiete besitzen. Die interferometrischen Merkmale unterstützen die Trennbarkeit der Vegetation und der urbanen Gebiete sowie die zwischen Brachland/Flächen mit geringer Vegetationsbedeckung und anderer Vegetation. Das objekt-basierte Vorgehen reduziert den Speckle und der *Decision Tree* Klassifikator erzeugt ein klares Regelwerk, welches als physikalisch basiert und übertragbar angesehen werden kann (QI ET AL., 2012).

ENGDAHL & HYYPPA, 2003 verwenden ERS-1/2 Tandem InSAR-Daten für die Landbedeckungsklassifikation von sechs Klassen eines Testgebietes nahe Helsinki. Die zu erfassenden Klassen sind:

1. Landwirtschaftliche Fläche/Offener Boden,
2. dichter Wald,
3. lichter Wald,
4. lockere urbane Bebauung,
5. dichte urbane Bebauung und
6. Wasser.

Anwendung finden 28 Intensitätsbilder und 16 Kohärenzbilder, wobei zwei Kohärenzbilder eine lange zeitliche Baseline besitzen. Die Autoren verwenden eine zweistufige Methode bei der zunächst das Wasser separat klassifiziert wird und anschließend die übrigen Klassen mittels einer

ISODATA-Klassifikation zugeordnet werden. Die Daten wurden temporal gemittelt und anhand einer *Principal Components Transformation* (PCT) die Anzahl der Eingangsbänder für die ISODATA-Klassifikation reduziert. Für die Genauigkeitsanalyse wurden Luftbilder, Karten und die nationale, finnische Forstinventur herangezogen. Die Gesamtgenauigkeit für die sechs Klassen lag bei 90 %. Die interferometrische Kohärenz lieferte für die Klassifikation die signifikanteren Informationen im Vergleich zu den reinen Rückstreuwerten (ENGDAHL & HYYPPA, 2003). Laut der Autoren ist dieses Ergebnis besser als vorangegangene Studien welche ERS-1/2 Tandem InSAR-Daten verwendeten. Als mögliche Gründe nennen ENGDAHL & HYYPPA, 2003 die sehr genauen Referenzdaten, die sehr genaue Georeferenzierung, die hohe Anzahl an Tandem-Paaren und die zweistufige Klassifikation.

Weitere jedoch nicht so umfangreiche Untersuchungen im Sinne der Klassentiefe beziehungsweise nur mit geringerem thematischen Überlapp basierend auf aktiven Fernerkundungsdaten sind PIERCE ET AL., 1998, KURVONEN & HALLIKAINEN, 1999, BRUZZONE ET AL., 2004, MCNAIRN & BRISCO, 2004, GAMANYA ET AL., 2007, WASKE & BRAUN, 2009 und MAGHSOUDI ET AL., 2013.

### 3.4.4 Synergistische Methoden

Unter synergetischen Methoden zur Erfassung von Biotoptypen, Landbedeckung und Landnutzung versteht man Verfahren, welche unterschiedliche Eingangsdaten für die Merkmalsgenerierung heranziehen. Diese Daten können z.B. thematische Layer oder aktive und passive Fernerkundungsdaten sein.

BARRETT ET AL., 2016 verwenden AVNIR-2 und PALSAR-Daten für die Klassifikation von Biotoptypen in drei Untersuchungsgebieten in Irland. Als Klassifikator dient ein pixel-basierter *Random Forest* (RF) Ansatz. Aus den AVNIR-2 Daten werden zusätzlich neun Vegetationsindices und aus dem NIR-Band acht Texturmaße extrahiert. Auch aus den PALSAR-Daten werden aus den Rückstreuungen zusätzlich acht Texturmaße extrahiert. Als weitere thematische Informationen verwenden die Autoren topografische Informationen (Höhe und Hangneigung) sowie Informationen über die Böden. Klassifiziert werden 15 Biotoptypen auf Basis verschiedener Eingangsdatenkombination aus multispektralen AVNIR-2 Daten (MS), der Textur aus den MS-Daten (TMS), den Vegetationsindices (VI), den radar-basierten PALSAR Daten (SAR), der Textur aus den SAR-Daten (TSAR) und den zusätzlichen thematischen Informationen (ANC). Die verwendeten Kombinationen sind:

1. MS + TMS,
2. SAR + TSAR,
3. MS + TMS + VI,
4. MS + ANC,
5. SAR + ANC,
6. MS + SAR,
7. MS + SAR + TMS + TSAR + VI und
8. MS + SAR + TMS + TSAR + VI + ANC.

Die Gesamtgenauigkeit variiert stark zwischen 59.8 % und 94.3 % unter Verwendung der verschiedenen Eingangsdatenkombinationen. Die höchste Genauigkeit konnte bei der Verwendung aller Eingangsdaten (MS + SAR + TMS + TSAR + VI + ANC) mit 93.2 % – 94.3% je nach Untersuchungsgebiet erreicht werden.

Die geringste Genauigkeit mit 68 % erreichte die Kombination SAR + TSAR. Generell zeigten hohe Gesamtgenauigkeiten bei den verschiedenen Datensätzen (>~85%) und der RF Klassifikator erwies sich als relativ stabil. Stärkere Abweichungen wurden innerhalb der verschiedenen Klassen beobachtet.

Die Autoren halten fest, dass die Verwendung nur der optischen Daten zu höheren Gesamtgenauigkeiten führt als die Verwendung der von nur SAR-Daten, betonen abschließend jedoch den Vorteil der Nutzung unterschiedlicher und in diesem Fall aller Datenquellen um die höchste Gesamtgenauigkeit zu erreichen.



SCHUSTER ET AL., 2015 verwenden je 21 RapidEye- und TerraSAR-X- Szenen für die Klassifikation von sieben Graslandbiotopen. Ziel der Studie ist es die Eignung der beiden Sensoren für die Klassifikation der Graslandbiotope zu evaluieren. Die Zeitreihen beider Sensoren werden getrennt voneinander betrachtet. In die Klassifikation gehen auf der einen Seite die Rückstreuungen für die SAR-Daten und auf der anderen Seite der NDVI (erzeugt aus NIR/Rot, rededge/Rot und NIR/rededge) aus den RapidEye-Daten ein. Als Klassifikationsalgorithmus wird ein pixel-basierter *Support Vector Machine* (SVM) Ansatz gewählt. Als Referenzdaten dienen zwischen 29 und 153 in-situ gemessene Punkte für die sieben Klassen. Die Referenzpunkte werden in 70 % Trainingsdaten und 30% Validationsdaten geteilt. Darüber hinaus findet ein Ansatz zur Merkmalsreduktion, ebenfalls basierend auf der SVM, Anwendung. Dies geschieht um zu ermitteln, wie viele Szenen notwendig sind um die maximale Genauigkeit, ausgedrückt durch das F-Maß und Kappa, je Sensor zu erreichen. Die erreichten Genauigkeiten liegen bei 0.842 F-Maß / 0.88 Kappa (NDVI-rededge/rot), 0.879 F-Maß / 0.9 Kappa (NDVI), 0.882 F-Maß / 0.9 Kappa (NDVI-NIR/rededge) und 0.893 F-Maß / 0.89 Kappa (TerraSAR-X). Somit liefern alle Datengrundlagen sehr ähnliche Genauigkeiten und variieren nur auf Basis der einzelnen Klassen stärker. Die größte Variation im F-Maß besitzt die Klasse *Caricion elatae* mit Werten zwischen 64 und 80. Im Hinblick auf die Eignung der beiden Sensoren und der Anzahl der Aufnahmen um die maximale Genauigkeit zu erreichen zeigt sich ein unterschiedliches Bild. Der NDVI basierend auf den RapidEye-Daten liefert nach fünf beziehungsweise sechs (NDVI - NIR/rededge) Zeitpunkten bereits die maximale Genauigkeit. Die Ergebnisse der auf den TerraSAR-X-Daten basierende Klassifikationen benötigen dagegen 15 Aufnahmen um die maximale Genauigkeit zu erreichen. Zusammenfassend erklären die Autoren, dass beide Sensoren ähnliche Ergebnisse liefern und beide Vor- beziehungsweise Nachteile haben. So benötigt man bei den TerraSAR-X Daten mehr Aufnahmen, diese wiederum sind jedoch einfacher, durch die Unabhängigkeit von Bewölkung, zu akquirieren. Bei den RapidEye-Daten werden weniger Daten benötigt. Diese sind jedoch schwieriger zu akquirieren und aufwändiger in der Vorprozessierung. Generell schlagen die Autoren eine synergistische Nutzung der Daten mittels robusterer und automatisierter Methoden für das Monitoring von Natura 2000 Biotopen und Biotoptypen vor.

ZHU ET AL., 2012 verwenden multi-temporale Landsat ETM+ und PALSAR-Daten des ALOS um 17 Landbedeckungsklassen im urbanen Raum zu kartieren. Der Beitrag der einzelnen Eingangsdaten zum Klassifikationsergebnis wurde anhand der Klassifikationsgenauigkeit ermittelt. Als Klassifikation wurde eine *Random Forest* verwendet. Unter Verwendung der PALSAR-Daten wurde eine Gesamtgenauigkeit von 30.99 % erreicht. Wurde die Textur erzeugt aus den PALSAR-Daten mit integriert stieg die Gesamtgenauigkeit auf 72.24 %. Eine einzelne Landsat-Szene erreichte eine Gesamtgenauigkeit von 77.96 %, wurden saisonal verteilte Landsat-Daten verwendete stieg die Gesamtgenauigkeit auf 86.86 % und bei Integration der Textur aus Landsat auf 92.69 %. Die Kombination aus passiven und aktiven Fernerkundungsdaten und der Texturinformationen steigerte die Gesamtgenauigkeit auf 93.82 %. Den Anstieg um 1.1 % erachten die Autoren dennoch als signifikant, da die Höhe des Anstieges in ihren Augen lediglich durch die schon sehr hohe Klassifikationsgüte aus den passiven Fernerkundungsdaten limitiert ist. Darüber hinaus stellen ZHU ET AL, 2012 fest, dass der Hauptteil des Anstieges der Klassifikationsgüte auf drei Klassen beschränkt ist. Die Autoren halten fest, dass die Kombination von aktiven und passiven Fernerkundungsdaten und deren Texturinformationen einen Mehrwert für die Landbedeckungsklassifikation im urbanen Raum besitzt.

Eine Quickbird Szene und fünf *fine-beam* (der Modus mit der höchsten räumlichen Auflösung von etwa 5 x 5 m) RADARSAT-SAR-Daten verwenden BAN ET AL., 2010 zur Klassifikation von 16 Landbedeckungsklassen im urbanen und landwirtschaftlich geprägtem Raum. Als Methode findet ein objekt- und wissensbasierter Ansatz Anwendung. Die Klassifikation von allen 16 Klassen mittels der Quickbird-Szene erreichte eine Gesamtgenauigkeit von 87.9 % und die basierend auf den multi-temporalen SAR-Fernerkundungsdaten, allerdings nur für 11 Klassen, eine ähnliche Klassifikationsgüte von 86.6 %. Mittels einer *decision level* Fusion, bei der ein im Voraus definiertes Kriterium oder Algorithmus genutzt wird um zwei Klassifikationsergebnisse zu kombinieren (DU ET



AL., 2009), werden beide Klassifikationsergebnisse zusammengeführt. Diese Herangehensweise verbesserte das Klassifikationsergebnis verschiedener Klassen. So konnte die Klassifikationsgüte von Soja von 71 % auf 90 %, bei Raps von 78 % auf 95 % und bei Grasland von 47 % auf 72 % gesteigert werden. Die Genauigkeit von urbanen Flächen blieb jedoch relativ konstant, da beide Datengrundlagen hier höhere Fehlklassifikationsraten aufwiesen. Auch bei dieser Untersuchung zeigt sich, dass eine Kombination von aktiven und passiven Fernerkundungsdaten zu einer Steigerung des Klassifikationsergebnisses führt.

Zu ähnlichen Ergebnissen im Hinblick auf die Verbesserung der Gesamtgenauigkeit der Klassifikation von verschiedensten Landbedeckungs- und Landnutzungsklassen unter Verwendung von SAR und optischen Daten kommen auch AMARSAIKHAN ET AL., 2007, BOURGEAU-CHAVEZ ET AL., 2009, CHUST ET AL., 2004, DUSSEUX ET AL., 2014, HAACK & KHATIWADA, 2010, HILL ET AL., 2005, HONG ET AL., 2015, HUANG ET AL., 2010, KUPLICH ET AL., 2000, ULLMANN ET AL. 2014, PETERS ET AL., 2011, SCHMIDT ET AL., 2017 sowie WASKE & VAN DER LINDEN, 2008.

Vergleichbare Synergieeffekte und damit einhergehende verbesserte Klassifikationsgenauigkeiten können auch bei der Kombination von:

1. LiDAR und multispektralen Daten (BORK & SU, 2007, GARCIA ET AL., 2011, MAXWELL ET AL., 2015, MÜCHER ET AL., 2015, POLYCHRONAKI ET AL., 2015),
2. Luftbildern und multispektralen/hyperspektralen Daten (LUCAS ET AL., 2008, POLYCHRONAKI ET AL., 2015) sowie
3. LiDAR und hyperspektralen Daten (ONOEJHUO & BLACKBURN, 2011, DALPONTE ET AL., 2012, SIMONSON ET AL., 2013) beobachtet werden.

### 3.4.5 Fernerkundung für die Landschaftselementkartierung

Die Kartierung von Landschaftselementen ist nur bedingt Bestandteil der Biotoptypenkartierung und wird deshalb im Hinblick auf den Stand der Forschung getrennt von dieser betrachtet. Allerdings gibt es auch nur wenige Studien die sich explizit mit der Detektion von Landschaftselementen befassen.

Eine dieser Studien wurde von TANSEY ET AL., 2009 durchgeführt. TANSEY ET AL., 2009 entwickeln mit dem Hintergrund der Erhaltung und Erweiterung der Biodiversität im Umfeld der landwirtschaftlichen Nutzflächen eine objekt-basierte Methode zur Kartierung von Landschaftselementen in einem landwirtschaftlich geprägten Gebiet in Südengland. Verwendet werden Daten des *Airborne Digital Sensor* (ADS) 40 mit fünf spektralen Kanälen (panchromatisch 465–680 nm, blau 430–490 nm, grün 535–585 nm, rot 610–660 nm und nahem infrarot 835–885 nm) sowie ein digitales Oberflächenmodell (DOM) generiert aus dem panchromatischen Kanal (aufgenommen mit drei unterschiedlichen Neigungswinkeln). Die Daten besitzen eine räumliche Auflösung von 0.25 m für die spektralen Bänder und 1 m / 5 m für das DOM. Ziel der Arbeiten ist die Ableitung von Heckenreihen, Grünland (Heckenbegleitstreifen) und Baumvegetation und deren räumliches Verhältnis zu landwirtschaftlichen Nutzflächen, um die vom *Department for Environment, Food and Rural Affairs* (DEFRA) vorgegebenen Richtlinien der Landschaftserhaltung überprüfen zu können. Für die Ableitung der einzelnen Landschaftselemente benutzen die Autoren spektrale und geometrische Informationen sowie die Objekthöhen abgeleitet aus dem DOM. Eine ausführliche Genauigkeitsanalyse wurde nicht durchgeführt, allerdings wird angemerkt, dass für einen kleineren Ausschnitt die für die DEFRA wichtigen Heckenbegleitstreifen mit einer Genauigkeit von 68% erfasst wurden. Um die Genauigkeit zu erhöhen schlagen die Autoren vor, bereits vorhandene thematische Informationen, wie z.B. Feldgrenzen in die Klassifikation mit einfließen zu lassen. Darüber hinaus wird angemerkt, dass die Beschreibung der Landschaftselemente durch die DEFRA nicht exakt durch die Klassifikation abgebildet werden kann, da durch die DEFRA auch Eigenschaften wie das Alter einer Hecke definiert sind und dieses aus multispektralen Luftbildern nicht extrahierbar ist. Wie auch ERIKSON, 2004 betonen

TANSEY ET AL., 2009 die herausragende Bedeutung einer möglichst realitätsnahen Segmentierung der Daten, um möglichst bereits vor der Klassifikation die Landschaftselemente als diskrete Objekte vorliegen zu haben. Insgesamt zeigen TANSEY ET AL., 2009 klar das Potential der objekt- und regelbasierten Klassifikation von Landschaftselementen mittels multispektraler, hochauflösender Fernerkundungsdaten.

THORNTON ET AL., 2006 verwenden *Quickbird*-Daten mit einer Auflösung von 2.6 m zur Erfassung von Landschaftselementen. Mit dem Hintergrund der räumlichen Abhängigkeit, also, dass benachbarte in diesem Fall Pixel mehr gemeinsam haben als weit entfernte (TOBLER, 1970), verwenden die Autoren einen sub-pixel Ansatz um die Genauigkeit bei der Klassifikation von Landschaftselementen zu erhöhen. Zunächst wurden die Daten mittels eines überwachten *fuzzy c-means* Ansatzes klassifiziert und anschließend mit einem Faktor fünf in Subpixel unterteilt. Anschließend wurde iterativ eine *pixel-swapping* (NIROUMAND ET AL, 2012) Methode verwendet, welche die räumliche Korrelation der Subpixel über das ganze Bild hin maximiert. Als Referenzdaten dienten Begehungsdaten. Die Genauigkeit der Ergebnisse lag zwischen 50 und 70 % je nach Klasse und der *Root Mean Square Error* (RMSE) zwischen 20 und 30 % (THORNTON ET AL., 2006).

THORNTON ET AL., 2007 entwickeln ihren Ansatz (THORNTON ET AL., 2006) unter Verwendung von Luftbildern mit einer Auflösung von 0.25 m weiter. Die Daten werden mittels eines einfachen Klassifikators, welcher die Mahalanobis-Distanz minimiert, klassifiziert und anschließend auf räumliche Auflösungen von 2.5 m beziehungsweise 5 m skaliert. Die geschieht um multispektrale Satellitenbilder zu simulieren. Anschließend wurde ähnlich ihrer vorangegangenen Veröffentlichung (THORNTON ET AL., 2006) iterativ eine *pixel-swapping* (NIROUMAND ET AL, 2012) Methode verwendet, welche die räumliche Korrelation der Subpixel über das ganze Bild hin maximiert (THORNTON ET AL., 2007). Die Genauigkeit der so entstandenen Klassifikation liegt bei 87 %. Um das Ergebnis weiter zu verbessern und vor allem die Kanten der Objekte der realen Welt in der Bildrepräsentation zu verbessern, wird durch die Autoren eine Texturkomponente (Anisotropie) den Daten hinzugefügt. Die Textur wird verwendet um die *pixel-swapping* Methode dahingehend zu verändern, dass die Wahrscheinlichkeit für die Generierung linearer Strukturen ansteigt. Dies führt zu einem Anstieg bei der Genauigkeit der Klassifikation bei linearen Strukturen um etwa 5 % (THORNTON ET AL., 2007).

Generell haben die Veröffentlichungen (THORNTON ET AL., 2006, THORNTON ET AL., 2007, TANSEY ET AL., 2009) gezeigt, dass unter Verwendung von multispektralen Daten und zusätzlichem Information (DOM, Textur) eine Genauigkeit bei der Erfassung unterschiedlicher Landschaftselemente zwischen 70 – 90 % erreicht werden kann.

### 3.5 Merkmalsauswahl

Durch die umfangreiche Datengrundlage (Kapitel 4.2) und der daraus resultierenden generierbaren Merkmalsvielfalt (Kapitel 5.1.1) ist es notwendig die Merkmale für die Klassifikation der jeweiligen Klassen auszuwählen, welche die Klassifikationsgüte maximieren. Da diese Merkmale nicht im Vorhinein bekannt sind, werden möglichst viele Merkmale aus den Daten generiert. Klassifikationsmethoden wie *k-nearest neighbour* angewendet auf eine große Merkmalsvielfalt liefern aufgrund ihres Designs jedoch nicht die optimalen Ergebnisse wogegen *Decision Tree* Algorithmen relativ unabhängig von der Merkmalsvielfalt sind, jedoch können auch diese von einer vorangegangenen Merkmalsaufwahl profitieren (NOVAKOVIC ET AL., 2011). Auch wird bei zunehmender Merkmalszahl der Hughes-Effekt (HUGHES, 1968) beobachtet. Dieser drückt sich dahingehend aus, dass mit zunehmender Merkmalsanzahl bei einer Klassifikation zunächst die Genauigkeit der Klassifikation steigt (COILLIE ET AL., 2007), jedoch ab einem bestimmten Punkt durch die Hinzunahme weiterer Merkmale die Genauigkeit wieder abnimmt (HUGHES, 1968, SHAHSHAHANI B. M. & LANDGREBE, 1994, TADJUDIN & LANDGREBE, 1999, CHI ET AL., 2008, PAL & FOODY, 2010).

Somit ist das Ziel der Merkmalsauswahl irrelevante, redundante oder verrauschte Merkmale zu entfernen um eine einfachere und präzisere Datenrepräsentation zu erhalten (JOHN ET AL., 1994, BLUM & LANGLEY, 1997, DASH & LIU, 1997, LIU & YU, 2005, TAN, 2007).

Die Vorteile sind:

1. Einsparung von Rechenzeit durch das Entfernen von irrelevanten oder redundanten Merkmalen,
2. Vereinfachung des Klassifikationsablaufs und Steigerung der Genauigkeit durch die Eliminierung der Einflüsse durch irrelevante, verrauschte oder redundante Merkmale und
3. ein verbessertes Verständnis der zugrundliegenden Daten und Klassen (DASH & LIU, 1997, KOHAVI & JOHN, 1997, KOLLER & SAHAMI, 1996, TAN, 2007).

#### 3.5.1 Maße, Kriterien und Methoden

In der Literatur finden sich für die Merkmalsauswahl eine Vielzahl von Methoden, Kriterien und Maße, im Folgenden wird ein Überblick über diese gegeben.

GUO ET AL, 2008 nennen als Kategorien beziehungsweise Kriterien für die Evaluation der Merkmale die:

1. euklidische Distanz,
2. die *probabilistic distance* (Chernoff (CHERNOFF, 1952), Jeffreys-Matusita (MATUSITA, 1955) oder Bhattacharyya (BHATTACHARYYA, 1943)),
3. die *divergence* (Kullback–Leibler (KULLBACK & LEIBLER, 1951)) und
4. die auf einer Korrelation basierenden Kriterien (PAL & FOODY, 2010).

TAN, 2007 nennt desweiteren auf Ranking basierte Filtermethoden welche auf Statistiken wie:

1. *Chi-Quadrat* Test (LIU & SETIONO, 1995),
2. T-Test (LIU et al., 2002),
3. F-Test (PENG ET AL., 2005) beruhen,
4. die MIT-Korrelation (*signal-to-noise*) (GOLUB ET AL., 1999) und
5. das Fisher Kriterium (FUREY ET AL., 2000).

So ist es ein weit verbreiteter Ansatz mittels des *Chi-Quadrat* Tests eine Merkmalsauswahl durchzuführen (LIU & SETIONO, 1995, NOVAKOVIC ET AL., 2011). Evaluert wird der Wert eines Merkmals im Hinblick auf eine Klasse anhand der *Chi-Quadrat* Statistik ( $\chi^2$ ). Als Nullhypothese wird angenommen, dass zwei Merkmale unabhängig voneinander sind (NOVAKOVIC ET AL., 2011). Umso größer die Werte von  $\chi^2$  werden, umso stärker widerspricht ein Merkmal der Nullhypothese und ist zur Klassentrennung geeignet (NOVAKOVIC ET AL., 2011).

TAN, 2007 nennt des Weiteren Kriterien die der Informationstheorie (ABE & KUDO, 2005, NOVAKOVIC ET AL, 2011) entstammen, wie:

1. *mutual information* (GUYON & ELISSEFF, 2003, PENG ET AL., 2005, YAO ET AL., 2010) und
2. Entropie-basierte Maße (LIU ET AL., 2005, DASH & LIU, 1999, DASH ET AL., 2002)

Zu den Entropie-basierte Kriterien gehören *information gain*, *gain ratio* und *symmetrical uncertainty* (NOVAKOVIC ET AL, 2011). Versteht man die Entropie im Sinne der Informationstheorie als ein Maß für den mittleren Informationsgehalt beziehungsweise im Umkehrschluss als ein Maß für das Rauschen innerhalb eines Datensatzes. So kann der *information gain* definiert werden als ein Maß welches die zusätzliche Information für die Güte von Y(Klasse) durch die Hinzunahme von X (Merkmal) anhand der Abnahme der Entropie (E) beschreibt (Formel 3.1) (HALL & SMITH, 1998, NOVAKOVIC ET AL, 2011).

$$\text{Information gain } (Y, X) = E(Y) - E(Y | X) \quad (3.1)$$

Eine Schwäche des *information gain* Kriteriums ist, dass Merkmale mit einer größeren Bandweite an Werten überschätzt werden auch wenn sie gegenüber anderen Merkmalen mit geringerer Bandbreite keinen zusätzlichen Nutzen haben (KAREGOWDA ET AL., 2010, NOVAKOVIC ET. AL, 2011).

Um diesen Umstand zu umgehen kann der *information gain* anhand der Entropie des zu untersuchenden Merkmals normalisiert werden (NOVAKOVIC ET AL, 2011). Dieses Maß wird *gain ratio* genannt (Formel 3.2) (KAREGOWDA ET AL., 2010, NOVAKOVIC ET. AL, 2011).

$$\text{Gain ratio } (Y, X) = (E(Y) - E(Y | X)) / E(X). \quad (3.2)$$

Der Wertebereich liegt zwischen 0 und 1 wobei ein Merkmal mit dem Wert 1 die untersuchte Klasse komplett beschreibt. Dieses Kriterium begünstigt Merkmale mit einer geringeren Merkmalsbandbreite (NOVAKOVIC ET AL, 2011).

Eine weitere Abwandlung des *information gain* ist die *symmetrical uncertainty*. Hierbei wird ähnlich dem *gain ratio* eine Normalisierung anhand der Entropie durchgeführt. Zusätzlich zu der Entropie des Merkmals  $E(Y)$  wie beim *gain ratio* wird bei der *symmetrical uncertainty* noch die Entropie der Klasse  $E(X)$  mit einbezogen (Formel 3.3).

$$\text{Symmetrical uncertainty } (Y, X) = 2 * (E(Y) - E(Y | X)) / E(Y) + E(X). \quad (3.3)$$

Durch die Multiplikation mit 2 wird der Wertebereich zwischen 0 und 1 erhalten, wobei wie beim *gain ratio* ein Merkmal mit dem Wert 1 die untersuchte Klasse komplett beschreibt (NOVAKOVIC ET AL, 2011). Auch die *symmetrical uncertainty* favorisiert aufgrund ihres Designs Merkmale mit einem geringeren Wertebereich (NOVAKOVIC ET AL, 2011).

Ein weiteres Kriterium für die Merkmalsauswahl ist die *significance*. AHMAD & DEY (2004) beschreiben die *significance* als ein Kriterium für die Merkmalsauswahl, welches als Prinzip zugrunde legt, dass ein signifikant zur Klassentrennung beitragendes Merkmal unterschiedliche Werte für die unterschiedlichen Klassen besitzt (AHMAD & DEY, 2004). Die relative Häufigkeit eines Merkmals verteilt über die Klassen enthält somit ein Maß über die Verbindung zwischen den Merkmalsausprägungen und den Klassen und umgekehrt (AHMAD & DEY, 2004). Die Verbindungen werden gegeneinander quantifiziert und gespeichert. Ein großer Vorteil dieser Methode ist seine hohe Performanz (AHMAD & DEY, 2004).

Ebenso durch eine hohe Performanz ausgezeichnet und vor allem geeignet um eine Vorauswahl der Merkmale für eine rechen-intensive Merkmalsauswahl zu treffen ist der *OneR* Ansatz entwickelt von HOLTE (1993) (NOVAKOVIC ET AL, 2011). Basierend auf simplen Klassifikationsregel aufgestellt anhand der Trainingsdaten werden Merkmale ausgewählt welche den geringsten Fehler ergeben, betrachtet wird immer nur ein Merkmal (NOVAKOVIC ET AL, 2011).

All diese Kriterien betrachten jeweils ein Zweiklassenproblem und erwarten normalverteilte Daten (GUO ET AL., 2008). Liegt ein Mehrklassenproblem, wie in dieser Arbeit, vor, dann können die paarweisen Ergebnisse entweder gemittelt werden oder eine Klasse herausgenommen und alle anderen Klassen zusammengefasst werden (GUO ET AL., 2008) um somit ein Zweiklassenproblem zu erzeugen. Durch diese Vorgehensweisen können allerdings Inkonsistenzen entstehen, da die Merkmale unterschiedlich zum Klassifikationsergebnis beitragen (GUO ET AL., 2008). Betrachtet man jede Klasse einzeln gegen alle anderen Klassen zusammengefasst und evaluiert anschließend den Einfluss jedes Merkmals auf die Klassifikationsgüte kann diese Inkonsistenz verhindert werden.

Des Weiteren wurden Methoden und Maße entwickelt welche diese Problematiken umgehen. In diesen Bereich fallen die von TAN, 2007 genannten *Wrapper* Ansätze angepasst für das Merkmalsranking beziehungsweise die Merkmalsauswahl, wie *Support Vector Machines* (SVMs) (MAO ET AL., 2005, WESTON ET AL., 2000, WESTON ET AL., 2002) und *Decision Trees* (BREIMAN, 2001) (TAN, 2007).

Die SVMs basieren auf der statistischen Lerntheorie (VAPNIK, 1995, PAL & FOODY, 2010) und werden ebenfalls zur Merkmalsauswahl verwendet (LI ET AL., 2016). Ziel ist es Hyperebenen zu definieren, welche den Merkmalsraum optimal trennen um die untersuchten Klassen zuordnen zu können (BOSER ET AL., 1992, CRISTIANINI & SHAW-TAYLOR, 2000, PAL & FOODY, 2010). Bei einem Zwei-Klassenproblem definiert sich die Hyperebene über den größten euklidischen Abstand der Summe der Abstände der jeweils benachbarten Punkte der beiden Klassen. Dies geschieht zunächst linear, indem ein Vektor (Richtung) und ein Offset anhand einer quadratischen Optimierung definiert werden (VAPNIK, 1995, PAL & FOODY, 2010). Sind die Klassen nicht linear trennbar wird eine Variable hinzugefügt, welche einen gewissen Grad an Fehlklassifikationen erlaubt. Hierbei wird die Hyperebene gesucht, welche die Klassen optimal trennt und die geringsten Fehlklassifikationen aufweist. Da jedoch die meisten Klassifikationsprobleme nicht linear lösbar sind verwendet die für die Merkmalsauswahl angewendete SVM-Implementierung eine nichtlineare Vektorfunktion, welche durch die Verwendung einer Kernel Funktion realisiert wird (VAPNIK, 1995, CRISTIANINI & SHAW-TAYLOR, 2000, PAL & MATHER, 2004, FOODY & MATHER, 2004, PAL & MATHER, 2006, PAL & FOODY, 2010).

Aufbauend auf der Methodik der SVMs entwickeln GUYON ET AL., 2002 den *Support Vector Machine Recursive Feature Elimination* (SVM-RFE) Ansatz zur Merkmalsauswahl (PAL & FOODY, 2010). Dieser Ansatz verwendet eine *objective function* (BEZDEK, 1981) als Kriterium für das Merkmalsranking (PAL & FOODY, 2010), auf dessen Grundlage eine Liste mit absteigender Trennbarkeitsfähigkeit der Merkmale erstellt wird. Dies wird iterativ auf Teilmengen der Merkmale und Klassen durchgeführt und mit jedem Durchlauf das Merkmal mit der geringsten diskriminatorischen Kraft entfernt (PAL & FOODY, 2010). Am Ende entsteht ein Ranking der Trennbarkeitsfähigkeit aller Merkmale im Hinblick auf die betrachteten Klassen (PAL & FOODY, 2010).

Auch der *Random Forest* (BREIMAN, 2001) Ansatz kann zur Merkmalsauswahl verwendet werden (STUMPF & KERLE, 2011, NOVACK ET AL., 2011, O'CONNELL ET AL., 2015, SCHULTZ ET AL., 2015, LI ET AL., 2016). Der *Random Forest* basiert auf einer Vielzahl an *Decision Tree* Klassifikatoren, bei welchem jeder *tree* auf einem Teil der Trainingsdaten und einem zufälligen Teil der Merkmale trainiert wird (PAL & FOODY, 2010). Ein Teil der Trainingsdaten wird dabei nicht zum Training der Klassifikatoren zugelassen (BREIMAN, 1996) und für die Merkmalsauswahl genutzt (PAL & FOODY, 2010). Dies geschieht anhand einer Bestimmung der Aussagekraft jedes Merkmals während des kompletten Klassifikationsprozesses (BREIMAN, 2001, DÍAZ-URIARTE & DE ANDRÉS, 2006, PAL & FOODY, 2010, GHIMIRE ET AL., 2010). Das Ranking der Merkmale geschieht anschließend auf der Basis des *Zscore*, welcher der Signifikanz eines jeden Merkmals entspricht (BREIMAN, 2001, PAL & FOODY, 2010).

Auch anderen Autoren entwickeln Methoden weiter um die Multiklassenproblematik zu umgehen. So zum Beispiel der Relief-Algorithmus weiterentwickelt von KONONENKO (1994). Der zugrundeliegende Relief-Algorithmus entwickelt durch KIRA & RENDELL (1992) bewertet die Aussagekraft (*W*) eines

Merkmals (X) in einem Zweiklassenproblem (ROBNIK-SIKONJA M. & KONONENKO I., 1997). Hierbei werden die nebeneinander gelegenen Repräsentationen des Merkmals untersucht, wobei zunächst eine zufällig gewählte Repräsentation (R) des Merkmals ausgewählt wird und die nächsten Nachbarn für die gleiche Klasse (*nearest hit* – H) und die zweite Klasse (*nearest miss* – M) ermittelt werden (ROBNIK-SIKONJA M. & KONONENKO I., 1997). Die Distanz zwischen den Repräsentationen geht dann in die Aussagekraft für dieses Merkmal ein. Dieser Prozess wird entweder n-mal (benutzerdefiniert) oder bis alle Repräsentationen getestet wurden wiederholt (ROBNIK-SIKONJA M. & KONONENKO I., 1997). Dieser Ansatz funktioniert jedoch nur bei diskreten und lückenlosen Attributrepräsentationen sowie zwei Klassen. KONONENKO (1994) entwickelte deshalb den Algorithmus dahingehend weiter, dass er nicht mehr nur einen Nachbarn untersucht, sondern eine Mittelung mehrerer *misses* und *hits* vornimmt. Somit werden die Merkmale und Klassen sowohl lokal, durch die Beachtung des Kontextes der Merkmale, als auch global, durch die mehrfachen Wiederholungen untersucht. Die veränderte Fassung (ReliefF) kann somit auch lückenhafte Daten sowie Multiklassenprobleme analysieren (ROBNIK-SIKONJA M. & KONONENKO I., 1997).



# 4 Arbeitsbasis

*"Landschaft - begrenzt und offen zugleich; Herzkammer Deutschlands, durch welche von jeher die Wasserströme fließen, die großen Schicksalsströme: falsche Rhetoren und eitle Schwätzer, welche dich halten wollen, schöpfen den Rhein in ein Sieb; deinen Kindern aber formst du dich willig wie eine Wasserkugel, die in sich ruht und fließt."*

Elisabeth Langgässer (1899 - 1950)

## 4.1 Untersuchungsgebiete

In diesem Kapitel werden die beiden in der Arbeit verwendeten Untersuchungsgebiete Gritzsch und Rostock vorgestellt.

Das Untersuchungsgebiet Rostock (Abbildung 1) umfasst das Rostocker Umland sowie die Rostocker Heide. Beide sind Teil des administrativen Bereichs der Hansestadt Rostock. Das Gebiet ist geprägt durch die Lage am Meer. Die Landschaft zeichnet sich durch eine flache, glazial Überprägung aus und befindet sich im Durchschnitt auf 13 m über dem Meeresspiegel. Das Klima entspricht dem warmgemäßigten Regenklima der mittleren Breiten, mit einer Jahresdurchschnittstemperatur (1961-1990) von 8,4 °C sowie ca. 590 mm Niederschlag pro Jahr (DWD, 2011).




Abbildung 1: Untersuchungsgebiet Rostock.

Das Gebiet der Rostocker Heide ist hauptsächlich durch Waldflächen geprägt. Diese setzen sich vorrangig aus Laubgehölzen (Buche, Birke, Erle, Eiche) und einem geringeren Teil Nadelgehölzen (Kiefer, Fichte) zusammen. Im Gebiet der Rostocker Heide befindet sich das Naturschutzgebiet Hütelmoor mit dem Heiligensee sowie das Gebiet um den Radelsee, welche durch Naßwiesen, Röhrichtbestände und Riede geprägt sind. Darüber hinaus gibt es im Untersuchungsgebiet kleinere Bereiche welche durch Trocken- und Magerrasen sowie Zwergstrauch- und Wacholderheiden geprägt sind. Im Westen und im Süden ist das Untersuchungsgebiet durch urbane Flächen geprägt. Der mittlere und östliche Teil des Untersuchungsgebietes ist dagegen durch landwirtschaftliche Nutzflächen geprägt.

Das Untersuchungsgebiet Grotzsch (Abbildung 2) liegt um die Kleinstadt Grotzsch südlich von Leipzig und erstreckt sich in südwestlicher Ausrichtung entlang der Weißen Elster und ist Teil des Leipziger Landes. Diese landwirtschaftlich geprägte Ebene besitzt im Untersuchungsgebiet kaum Relief und liegt im Durchschnitt auf etwa 120 m über Normalnull (NN). Das Klima entspricht einem trockenen Klima der unteren Berglagen und Hügelland. Die Jahresdurchschnittstemperatur (1961-1990) beträgt etwa 9.0 °C der jährliche Niederschlagsdurchschnitt liegt etwa bei 550 mm (DWD, 2011). Große Teile des Untersuchungsgebietes sind landwirtschaftlich geprägt und umfassen Ackerflächen sowie Wirtschaftsgrünland. Die Bereiche entlang der Weißen Elster sind durch Ruderalfluren und Laubbaumbeständen geprägt.




Abbildung 2: Untersuchungsgebiet Grotzsch.



## 4.2 Datengrundlage

Die in der Arbeit verwendeten Daten decken ein weites Spektrum der in der Fernerkundung vorhandenen Aufnahmemöglichkeiten ab. Die verwendeten optischen und SAR-Satellitendaten sowie die zusätzlich verwendeten Daten werden im Folgenden beschrieben.

### 4.2.1 RapidEye

Die von der RapidEye AG zur Verfügung gestellten Daten können in zwei Prozessierungslevel, L1B und L3A, bezogen werden. Level 1B-Produkte (L1B), auch als RapidEye Basic bezeichnet, sind radiometrisch und geometrisch korrigiert. Das heißt, dass für die Szenen folgende Korrekturen durchgeführt wurden:

1. Radiometrische Korrekturen, welche die Korrektur der relativen, radiometrischen Unterschiede zwischen den Detektoren, das Füllen der Lücken der ausgefallenen Detektoren und die Umwandlung der Daten in absolute radiometrische Werte basierend auf vordefinierten Kalibrationskoeffizienten beinhaltet und
2. Geometrischen Korrekturen, welche die Korrektur der internen Detektorengeometrie der zwei Sensenchipsätze in ein virtuelles Array, die Beseitigung von optischen Effekten hervorgerufen durch die Optik des Sensors und die Koregistrierung der Kanäle um eine korrekte Überlappung der spektralen Bänder zu gewährleisten, umfassen (RAPIDEYE AG, 2010).

Die Level 1B Produkte werden im *National Imagery Transmission Format* (NITF) 2.0 Format mit einer räumlichen Auflösung von 6,5 m und einer radiometrischen Auflösung von 16 Bit ausgeliefert. Die geometrische Genauigkeit der L1B-Produkte bei Nadir-Aufnahmen über relativ flachem Gelände (Hangneigung < 10°) wird mit 45 m CE90 (RMSE = 21 m) bei der Verwendung von GCPs abgeleitet aus einem Landsat Mosaik beziehungsweise 23 m CE90 (RMSE = 11 m) bei der Verwendung von GCPs mit höherer Genauigkeit, wie z.B. in den USA vorhanden, angegeben (RAPIDEYE AG, 2010).

Tabelle 3: RapidEye Produkttypen

Produkt-name	Lagegenauigkeit			Ortho- rektifizierung	Ausgelieferte Auflösung
	CE90 (m)	RMSE (m)	NMAS		
L1B	45*/23**	21* / 11**	-	Nein	6.5 m
L3A	30* / 14**	15* / 6**	1:25.000	Ja	5 m

\* GCPs aus Landsat-Mosaik

\*\* GCPs mit höherer Genauigkeit (keine genauen Angaben der Quellen seitens der RapidEye AG)

Das zweite durch die RapidEye AG zur Verfügung gestellte Prozessierungslevel wird als Level 3A oder auch RapidEye Ortho bezeichnet. Das RapidEye Ortho Produkt ist radiometrisch, geometrisch und Sensoren-korrigiert. Bei der geometrischen Korrektur finden sowohl sensor-bezogene Korrekturen anhand der Satellitentelemetrie und der Ephemeriden als auch eine Orthorektifizierung anhand eines DGMs und GCPs statt.

Die Daten des L3A werden in 25 x 25 km großen Kacheln mit einer räumlichen Auflösung von 5 m ausgeliefert. Die geometrische Genauigkeit der L3A-Produkte wird mit mindestens 30 m CE90 (RMSE = 15 m) angegeben. Bei genaueren GCPs wie in Europa und den USA vorhanden können Genauigkeiten von 14 m CE90 (RMSE = 6 m) erreicht werden. Diese Werte gelten, wie auch bei den Level 1B Produkten, bei Nadir-Aufnahmen über flachem Gelände mit einer Hangneigung unter zehn Grad (RAPIDEYE AG, 2010). Für die vorliegende Arbeit wurden Level 1B Produkte für die beiden Untersuchungsgebiete verwendet. Abbildung 3 gibt einen Überblick über die RapidEye Datenakquisition. Bei der Betrachtung der Aufnahmezeitpunkte fällt auf, dass die Szenen im August 2009 beziehungsweise Juni und Juli 2010 aufgenommen wurden und somit eine detaillierte phänologische Auswertung der Daten mit diesen Aufnahmezeitpunkten nicht möglich ist. Spektral nehmen die RapidEye-Daten durch das

Vorhandensein des rededge Kanals und der hohen Wiederholrate eine Sonderstellung unter den hochauflösenden Satellitendaten ein. Informationen aus dem rededge Bereich des elektromagnetischen Spektrums waren bis dato nur in geringerer räumlicher Auflösung (z.B. Meris) oder geringerer räumlicher Abdeckung beziehungsweise Wiederholrate (z.B. Hymap oder WorldView-2) vorhanden.

#### 4.2.2 TerraSAR-X

Der in einer Zusammenarbeit des *Deutschen Zentrums für Luft- und Raumfahrt (DLR)* und der *EADS Astrium GmbH* realisierte TerraSAR-X Satellit wurde am 15. Juni 2007 gestartet. Darüber hinaus wurde am 21. Juni 2010 der baugleiche Satellit TanDEM-X gestartet. Die in dieser Arbeit verwendeten Daten basieren ausschließlich auf Aufnahmen des TerraSAR-X. Somit wird im Folgenden auch ausschließlich auf die Charakteristik des TerraSAR-X eingegangen. Das TerraSAR-X-System ist ein *side-looking X-Band synthetic aperture radar (SAR)* und arbeitet mit einer Wellenlänge von 31 mm. Der Satellit wurde mit dem Hintergrund konzipiert einer Vielzahl von Anwendungen als Grundlage dienen zu können. Um dies zu gewährleisten wurden vier Aufnahmemodi definiert (EINER ET AL., 2009). Die zur Verfügung stehenden Modi sind:

1. *Stripmap Modus (SM)* in single oder dual Polarisation,
2. *High Resolution Spotlight Modus (HS)* in single oder dual Polarisation,
3. *Spotlight Modus (SL)* in single oder dual Polarisation sowie
4. *ScanSAR Modus (SC)* in single Polarisation.

Für die Arbeit wurden ausschließlich Daten des Stripmap Modus (SM) in dualer Polarisation verwendet. Diese Entscheidung wurde getroffen, um eine komplette Abdeckung mit einer Szene für einen größeren Bereich durch die Stripmap-Daten zu erhalten. Hierbei wurde ein Kompromiss zwischen räumlicher Abdeckung und räumlicher Auflösung eingegangen, d. h., ein größeres Gebiet konnte mit geringerer räumlicher Auflösung abgedeckt werden.

Tabelle 4: Überblick über den TerraSAR-X Stripmap Modus (SM).

<i>Stripmap Modus</i>	
Szenengröße	30 km /15 km (single pol. / dual pol.) (ground range) x 50 km (azimuth)
Einfallswinkel	20° - 45°
Räumliche Auflösung (Azimut)	3.3 m (6.6 m dual pol.)
Räumliche Auflösung (Ground range)	1.70 m - 3.49 m
Polarisation	HH oder VV (single) HH/VV, HH/HV, VV/VH(dual)

Die Szenengröße beim Stripmap Modus für die dual polarisierten Daten liegt bei 15 km (ground range) und 50 km (Azimut) und die single polarisierten Daten bei 30 km (ground range) und 50 km (Azimut) (vgl. Tabelle 4). Die räumliche Auflösung beim Stripmap Modus variiert je nach Einfallswinkel zwischen 3.3 m (single Polarisation) - 6.6 m (dual Polarisation) (Azimut) und 1.70 m - 3.49 m (ground range). Der Aufnahmewinkel kann zwischen 20° und 45 ° definiert werden. Als Polarisationen stehen für den Stripmap Modus HH und VV als single Polarisationen und HH/VV, HH/HV und VV/VH als duale Polarisationen zur Verfügung. Die Szenengröße für die High Resolution Spotlight Modus Daten liegt bei 10 km (ground range) x 5 km (Azimut). Die räumliche Auflösung beim High Resolution Spotlight Modus variiert je nach Einfallswinkel zwischen 1.1 m (single Polarisation) - 2.2 m (dual Polarisation) (Azimut) und 1.48 m - 3.49 m (ground range). Als Polarisationen stehen für den High Resolution Spotlight Modus HH und VV als single Polarisationen und HH/VV als duale Polarisationen zur Verfügung.

### 4.2.3 Sentinel-1

Die Sentinel-1 Konstellation besteht aus zwei baugleichen C-Band SAR-Satelliten. Sentinel-1 besitzt vier Aufnahmemodi:

1. *Stripmap* (SM),
2. *Interferometric Wide swath* (IW),
3. *Extra Wide swath* (EW) und
4. *Wave* (WV) (ESA, 2018A).

Der Standardmodus für Sentinel-1 über Land ist IW mit einer Aufnahmebreite von 250 km und einer räumlichen Auflösung von etwa 20 m (Level-1). Die möglichen Produktlevel sind *Level-0*, *Level-1 (SLC)*, *Level-1 (GRD)* und *Level-2 (OCN)*. *Level-0* sind die system-inhärenten Korrekturen beinhaltenden Rohdaten, *Level-1 Single Look Complex (SLC)* beinhaltet komplexe Amplituden- und Phasenbilder und *Level-1 Ground Range Detected (GRD)* die *multi-looked* Intensitätsbilder (ESA, 2018A). *Level-2 Ocean (OCN)* ist ein spezielles Format für die Aufnahme über den Ozeanen und ist optimiert für die Erfassung von geophysikalischen Parametern über Wasser (ESA, 2018A). Verwendung finden 25 Szenen (*Level-1 GRD*) im Jahr 2017 mit einem Abstand von etwa 15 Tagen (Abbildung 4).

### 4.2.4 Sentinel-2

Die Sentinel-2 Konstellation besteht aus zwei baugleichen Satelliten, bestückt mit dem *SENTINEL-2 Multispectral Instrument (MSI)* entwickelt und gebaut von *Airbus Defence and Space*. Das MSI besitzt 13 spektrale Kanäle mit 10 m (vier Bänder), 20 m (sechs Bänder) und 60 m (drei Bänder) räumlicher Auflösung (ESA, 2018B). Die Daten können in zwei Formaten bezogen werden:

1. *Level-1C* und
2. *Level-2A*.

*Level-1C* Daten beinhalten *top-of-atmosphere* Radianzen in 100 x 100 km Kacheln geometrisch korrigiert (UTM/WGS84.) Die *Level-1C* Daten sind global für den gesamten bisherigen Aufnahmezeitraum verfügbar.

Die *Level-2A* Daten, welche nur für Europa und einen begrenzt in die Vergangenheit reichenden Zeitraum verfügbar sind, enthalten atmosphären-korrigierte Daten (*bottom-of-atmosphere* Reflektanzen) ebenfalls in 100 x 100 km Kacheln geometrisch korrigiert (UTM/WGS84). Für die Arbeit verwendet werden *Level-1C* Daten aus dem Jahr 2017 mit einer Wolkenbedeckung unter zehn Prozent. Dies resultiert in elf Aufnahmezeitpunkten, wie in Abbildung 4 dargestellt. Die Daten wurden anhand ihrer *gains* und *offsets* auf einheitliche Radianzwerte gebracht. Durch einen zur räumlichen Schärfung nutzbaren Regressionsfilter (DLR, 2002) werden alle Kanäle auf eine räumliche Auflösung von 10 m mittels des spektral-benachbarten 10 m Kanals gebracht. Anschließend werden die Daten wie in Kapitel 4.3 beschrieben weiterverarbeitet.




Abbildung 3: RapidEye und TerraSAR-X Abdeckungen für die Untersuchungsgebiete Rostock und Groitzsch für die Jahre 2009 und 2010.




Abbildung 4: Sentinel-1 und Sentinel-2 Abdeckungen für das Untersuchungsgebiet Rostock für das Jahr 2017.

#### 4.2.5 Referenzdaten und thematische Daten

Für die Untersuchung konnte auf bereits vorhandene Referenzdaten wie die Biotop- und Landnutzungskartierung der Bundesländer Mecklenburg-Vorpommern (BNTK) und Sachsen (BLNTK) zurückgegriffen werden. In den Daten wird über den Ist-Zustand der Landschaftsausstattung Auskunft gegeben. Die Erstellung der Datensätze durchläuft verschiedene Prozessierungsschritte. Als Grundlage dienen unter anderem Color-Infrarot-Luftbilder (CIR-Luftbilder) welche durch stereoskopische Betrachtung und Codierung gemäß der Landesweiten Kartierschlüssel interpretiert werden. Anschließend folgen eine Digitalisierung der analogen Zeichenfolien und eine Plausibilitätsprüfung. Die vorgestellten Referenzdaten dienen dem Training und der Validation der Klassifikation, werden jedoch ebenfalls dazu verwendet Klassen in den Satellitendaten zu identifizieren und somit Testflächen zu generieren. Die Biotop- und Landnutzungskartierung der Bundesländer Mecklenburg-Vorpommern (BNTK) und Sachsen (BLNTK) wurden als Polygon-Vektordaten in zwei Zeitschnitten geliefert. Wobei der erste Zeitschnitt (1991 beziehungsweise 1993) die flächendeckende Erstkartierung und der zweite Zeitschnitt (2003 beziehungsweise 2005) eine selektive Kartierung einzelner Flächen darstellte. Wie in Abbildung 5 dargestellt variieren die Zeitschnitte für einige Flächen stark. Auffällig ist, dass die ältere Kartierung in einigen Gebieten die genauere Kartierung ist. Die Vektordaten unterlaufen einer sechsteiligen Vorverarbeitung:

1. Import ins GIS und Umprojizierung auf UTM Zone 33N / WGS 84,
2. Zuschneiden der Daten auf die Untersuchungsgebiete,
3. Konvertierung der Polygondaten in Punktdaten (innerhalb des Ursprungspolygons),
4. Zuweisung der Originalklassen für die Übertragbarkeit zwischen den Untersuchungsgebieten,
5. Visuelle Validierung der Punkte und Klassen anhand der LiDAR-Daten und der Luft- und Satellitenbilddaten,
6. Eliminierung der nicht-klassifizierbaren beziehungsweise unlogischen (falschen) Punkte.

Des Weiteren stehen für Teile beider Untersuchungsgebiete Digitale OrthoPhotos (DOP) aus den Jahren 2008 (Rostock) beziehungsweise 2009 (Groitzsch) zur Verfügung. Diese Daten werden als Grundlage für die geometrische Korrektur und zur Evaluierung beziehungsweise Validierung der Referenzdaten aus BNTK und BLNTK verwendet. Die Daten werden in Kacheln im Gauß-Krüger System geliefert und wurden zunächst zusammengeführt und anschließend auf UTM Zone 33N / WGS 84 umprojiziert.

Darüber hinaus stehen hochauflösende, digitale Oberflächenmodelle aus den Jahren 2006 (Rostock) und 2010 (Groitzsch) zur Verfügung. Diese Daten werden als ASCII xyz Punkte geliefert und werden auf die native räumliche Auflösung (2 m in Rostock und 1 m in Groitzsch) der Befliegung gerastert. Anschließend werden die Daten auf UTM Zone 33N / WGS 84 umprojiziert und die Bodenpunkte aus

dem Datensatz entfernt. Das somit entstandene normalisierte digitale Oberflächenmodell (nDOM) diene als Eingangsdatensatz für die Klassifikation.




Abbildung 5: Vergleich der Zeitschnitte 1991 (a) und 2003 (b) der BNTK (Mecklenburg-Vorpommern) – gelb, orange und rot entsprechen Grünlandklassen und grün Waldklassen - und einem Echtfarbenausschnitt einer RapidEye Szene von 2009 (c).

Als weitere Informationsquelle dienen die OpenStreetMap (OSM) Daten für Mecklenburg-Vorpommern und Sachsen (OSM, 2015). Dieser ständig aktualisierte Datensatz liefert Informationen über unter anderem Gebäudegrenzen, Straßen und Bahntrassen sowie Flüssen und Gewässerflächen. Diese Daten werden teilweise als Referenz in die Klassifikation mit einbezogen. Da die Daten als Vektoren bereits in UTM Zone 33N / WGS 84 vorlagen ist keine weitere Vorverarbeitung notwendig.

#### 4.2.6 Datensätze

Aus den im vorangegangenen beschriebenen Daten werden drei Datensätze für die weiteren Analysen zusammengestellt:

4. Entwicklungsdatensatz Rostock,
5. Übertragbarkeitsdatensatz Groitzsch und
6. Übertragbarkeitsdatensatz Rostock.

Der Entwicklungsdatensatz Rostock umfasst die RapidEye- und TerraSAR-X-Daten, sowie die Referenzdaten und thematischen Daten für das Untersuchungsgebiet Rostock. Basierend auf diesem Datensatz wird der Klassifikationsablauf inklusive Merkmalsauswahl entwickelt.

Der Übertragbarkeitsdatensatz Groitzsch umfasst die RapidEye- und TerraSAR-X-Daten sowie die Referenzdaten und thematischen Daten für das Untersuchungsgebiet Groitzsch. Mit diesem Datensatz wird getestet inwieweit sich die Methode auf eine anderes Untersuchungsgebiet mit ähnlicher Datenbasis übertragen lässt.

Der Übertragbarkeitsdatensatz Rostock beinhaltet die Sentinel-1- und Sentinel-2-Daten sowie die Referenzdaten und thematischen Daten für das Untersuchungsgebiet Rostock. Auf Grundlage dieses Datensatzes wird getestet, ob sich die Methode auf eine veränderte Datenbasis übertragen lässt. Durch die hohe Datendichte innerhalb dieses Datensatzes wird dieser Datensatz zweigeteilt, zum einen in einen mit den anderen Datensätzen vergleichbaren Datensatz und zum anderen in einen Datensatz für den zusätzlich multi-temporale Merkmale erzeugt werden.

Für alle Datensätze werden die Synergieeffekte evaluiert.

### 4.3 Vorverarbeitung der optischen Satellitendaten

Das Ziel der Vorverarbeitung der optischen Satellitendaten ist die Schaffung einer einheitlichen Datenbasis im Hinblick auf ihre geometrische sowie radiometrische Genauigkeit.

#### 4.3.1 Geometrische Korrektur

Die optischen Satellitendaten werden anhand der in Kapitel 4.2.5 angesprochenen Digitalen OrthoPhotos im ersten Schritt der Vorverarbeitung, der geometrischen Korrektur, auf eine einheitliche räumliche Lage gebracht. Korrigiert werden Lageungenauigkeiten hervorgerufen durch nicht-systeminhärente Fehler, wie die Bewegung der Erde und die Erdkrümmung und systeminhärente Fehler, hervorgerufen durch die Aufnahmegeometrie und die Geschwindigkeit, Höhe und Stellung des Sensors (DOXANI & STAMOU, 2005, ERDAS INC., 2005, GIBSON & POWER, 2000, LILLESAND & KIEFER, 2008, MITRI, 2007). Benötigt werden geeignete *Ground Control Points* (GCPs), welche die Lageabweichungen zwischen den Satellitendaten und den Orthophotos wiedergeben. Diese werden automatisch anhand spektraler Merkmale aus den Bilder extrahiert, manuell überprüft und stark abweichende oder falsche Punkte entfernt. Mittels eines polynomialen Models dritter Ordnung werden die Daten auf eine einheitliche Lage korrigiert. Als Methode für das *Resampling* wird der *Nearest Neighbour*-Ansatz verwendet. Tabelle 5 zeigt die verwendeten Parameter: unter anderem das Datum der verarbeiteten Szenen, die Anzahl der GCPs und den resultierenden RMSE am Beispiel der RapidEye Daten. Die Anzahl der Punkte variiert mit dem Überlapp der beiden Datensätze.

Tabelle 5: Parametrisierung und Genauigkeiten der Orthorektifizierung.

Sensor	Testgebiet	Datum	GCP Anzahl	RMSE
RapidEye	Rostock	20.08.2009	998	0.56
		06.06.2010	723	0.65
		09.07.2010	812	0.60
		20.07.2010	863	0.63
	Groitzsch	19.08.2009	203	0.79
		05.06.2010	243	0.98
		03.07.2010	182	0.88

Für die Sentinel-2 Daten ist eine Abschätzung der räumlichen Ungenauigkeiten aufgrund der unterschiedlichen räumlichen Auflösung im Vergleich zu den Luftbildern schwierig. Die teilweise sichtbaren räumlichen Ungenauigkeiten liegen jedoch im sub-pixel Bereich und werden nicht korrigiert.

#### 4.3.2 Atmosphärenkorrektur

Der zweite Schritt der Vorverarbeitung ist die radiometrische Korrektur oder auch Atmosphärenkorrektur. Nach RICHTER (2008) besteht das Ziel der Atmosphärenkorrektur in der Ableitung von physikalischen Landoberflächenparametern (z.B. Reflexion, Emission oder Oberflächentemperatur) aus optischen Satellitendaten. Zu diesem Zwecke müssen Einflüsse resultierend aus Aerosolen und Gasen in der Atmosphäre, der Sonneneinstrahlung und der Aufnahmegeometrie des Sensors bei der Korrektur berücksichtigt werden (RICHTER, 2008).

Die radiometrische Korrektur für Untersuchungen, basierend auf einem Satellitenbild ist unnötig da keine Übertragbarkeit angestrebt wird (CHEN ET AL., 2005, SONG ET AL., 2001). Bei multi-temporalen Datensätzen oder bei Ansätzen mit dem Anspruch der Übertragbarkeit muss eine radiometrische Korrektur durchgeführt werden (CHEN ET AL., 2005, SONG ET AL., 2001). Die Verwendung von Vegetationsindices impliziert die vorhergehenden radiometrische Korrektur. MYNENI ET AL., 1994



untersucht den Einfluss der radiometrischen Korrektur auf den NDVI. Die *Top-of-Atmosphere* (TOA)-Werte (ohne Korrektur) des NDVI sind demnach immer geringer als die *Top-of-Canopy* Werte simuliert anhand eines Vegetation/Atmosphäre-Strahlungstransfermodells (SONG ET AL., 2001). Veränderungen der NDVI-Werte durch Einflüsse aus der Atmosphäre können bis zu 50 % über Vegetation betragen (VERSTRAETE, 1994, SONG ET AL., 2001). In der Arbeit wird eine absolute radiometrische Korrektur (CHEN ET AL., 2005, DU ET AL., 2002, SONG ET AL., 2001) durchgeführt. Im ersten Schritt werden die Grauwerte anhand von *Gain* und *Bias* (oft auch *Offset*)), welche in den Metadaten der Satellitenszenen mitgeliefert werden, in am Sensor empfangene Strahlung umgewandelt. Im zweiten Schritt wird diese vom Sensor empfangene Strahlung in absolute Oberflächenstrahlung umgewandelt (CHEN ET AL., 2005).

Die Prozessierung der Satellitendaten wurde mit Hilfe der *Atmospheric/Topographic Correction 2(ATCOR2)* -Software durchgeführt. Als Input dienen eine Satellitenszene (*Radianzen*), der verwendete Sensor, der Neigungswinkel des Sensors (*sensor tilt angle*), der Azimutaufnahmewinkel des Sensors (*view azimuth angle*), der Sonnenzenitwinkel (*solar zenith*) und der Sonnenazimutwinkel (*solar azimuth*) ermittelt aus den Metadaten. Der Aerosoltyp und die optische Dichte können aus der Szene abgeleitet werden, aber auch durch Standardwerte belegt werden (RICHTER, 2006).

Die Kalibrierung der Reflexionen geschieht mit den bereits angesprochenen Parametern, auch Kalibrierungskoeffizienten,  $c_0$  (Gain) und  $c_1$  (Bias), welche ebenfalls in den Metadaten der Szenen für jeden Kanal zu finden sind (MARKHAM & BARKER, 1986, TEILLET ET AL., 2006). Bei der Prozessierung der RapidEye Szenen fiel auf, dass sowohl die in *ATCOR* implementierten Kalibrierungsfiles als auch die in den Metadaten publizierten Kalibrierungskoeffizienten -inklusive der systeminhärenten Umwandlung der Strahlungseinheiten der Metadaten von  $\text{Wm}^{-2}\text{sr}^{-1}\mu\text{m}^{-1}$  in die *ATCOR* verwendete Form:  $\text{mWcm}^{-2}\text{sr}^{-1}\mu\text{m}^{-1}$  (vgl. RICHTER, 2008), keine zu erwartenden spektralen Signaturen für eindeutig identifizierbare Landbedeckungsklassen lieferten. Somit mussten die Kalibrierungsfiles manuell angepasst werden. Bei dieser Anpassung wurden anhand von Referenzspektren die Kalibrierungskoeffizienten für die jeweiligen Szenen ermittelt. Die Koeffizienten mussten teils stark angepasst werden und variieren relativ um bis zu 30 %.

Tabelle 6: Kalibrationskoeffizienten der RapidEye-Szenen des Untersuchungsgebietes Rostock.

Kanal	$c_0 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$	$c_1 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$	$c_1 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$	$c_1 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$
	alle Zeitpunkte	20.08.2009	06.06.2010	09.07.2010
1	0	0.00120267	0.001414	0.001179
2	0	0.00125	0.001398	0.001201
3	0	0.001432	0.001898	0.001392
4	0	0.00158433	0.001773	0.001623
5	0	0.000795	0.001052	0.000986

Tabelle 7: Kalibrationskoeffizienten der RapidEye-Szenen des Untersuchungsgebietes Groitzsch.

Kanal	$c_0 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$	$c_1 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$	$c_1 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$	$c_1 [\text{mW cm}^{-2}\text{sr}^{-2}\mu\text{m}^{-1}]$
	alle Zeitpunkte	19.08.2009	05.06.2010	03.07.2010
1	0	0.001381	0.001132	0.000979
2	0	0.001320	0.001021	0.000890
3	0	0.001651	0.001496	0.001115
4	0	0.001306	0.001186	0.001339
5	0	0.000800	0.000678	0.000853

Das durch die Verwendung der Kalibrierungskoeffizienten (Tabelle 6 und Tabelle 7) zunächst entstehende *Radiance Image* dient der Berechnung des *Reflectance Image* welches die realen Reflexionen der einzelnen Pixel enthält.

Für die Sentinel-2 Daten konnten die Werte aus den Metadaten der jeweiligen Szene für die Korrektur verwendet werden.

Um die Ergebnisse der Atmosphärenkorrektur zu beurteilen wird im Folgenden ein Überblick über die Genauigkeit der Atmosphärenkorrektur mit ATCOR gegeben. Laut RICHTER, 2014 liegt die Genauigkeit der Algorithmen zur Berechnung der Oberflächenreflektanzen mit ATCOR bei 10% (relativ) bei Reflektanzen unter 20 % (absolut) und bei 5 – 10 % (relativ) bei höheren Reflektanzen. Hierbei ist allerdings von einer atmosphärisch, klaren Szene auszugehen. Dies würde bei einer Vegetationsfläche mit 30 % Reflexion im NIR und 5 % im roten Wellenlängenbereich eine Spannbreite von 27 % - 33 % im NIR und 4,5 – 5,5 % im roten Bereich bedeuten. Hierzu kommt die spektrale (Un-)Genauigkeit der Satellitendaten. Diese wird für RapidEye mit etwa 2,5 - 5 % beziffert. Vergleicht man verschiedene Messzeitpunkte miteinander, kommen zusätzlich die unterschiedlichen Beleuchtungs- und Beschattungseffekte sowie die BDRF Effekte hinzu. Diese fügen eine relative Ungenauigkeit von 10 % (Beleuchtung / Beschattung) und 5 % BDRF Effekte hinzu (RICHTER, 2014). Somit ergibt sich das untenstehende Fehlerbudget:

$$\text{Relativer Fehler} = (\text{Spektrale Genauigkeit des Sensors}) * (\text{Genauigkeit ATCOR}) * (\text{Beleuchtung / Beschattung}) * (\text{BRDF Effekte})$$

$$\text{Untere Grenze (relativer Fehler)} = 0.75 = 0.975 * 0.90 * 0.90 * 0.95$$

$$\text{Obere Grenze (relativer Fehler)} = 1.30 = 1.025 * 1.10 * 1.10 * 1.05$$

Überträgt man diese Berechnung auf die Werte aus den Satellitendaten und den gemessenen Referenzspektren (CLARK ET AL., 2007) erhält man das in Tabelle 8 gezeigte Bild. Es zeigt sich, dass 8 von 15 Werten innerhalb der Fehlertoleranz liegen. Für Wasser liefern die Werte im roten, rededge und NIR Kanal zu hohe Werte. Dies lässt auf von der Wasseroberfläche direkt zum Sensor zurückgeworfenes Sonnenlicht (*sun glint*) bedingt durch die Aufnahmegeometrie schließen. Die Kiefernflächen liefern im blauen und grünen Wellenlängenbereich leicht zu hohe Werte und die Wiesenfläche im blauen und roten Wellenlängenbereich leicht zu tiefe Werte. Dies kann durch die unterschiedliche phänologische Phase bedingt sein, kann aber nicht klar definiert werden. Auch sind die absoluten Werte sehr klein und somit die absoluten Abweichungen auch als eher gering einzuschätzen. Für die restlichen Szenen zeigt sich ein sehr ähnliches Bild mit teils Fehlern außerhalb der Toleranz bei sehr kleinen absoluten Werten (< 5 %) und guten Ergebnissen bei absoluten Werten über 10 %.

Tabelle 8: Reflektanzen im Vergleich mit den Referenzmessungen und den Fehlergrenzen.

Wasser	Reflektanzen 09.07.2010	Referenzmessung	Untere Grenze	Obere Grenze
Blau	4,46875	5,6	4,2	7,28
Grün	4,3875	4	3	5,2
Rot	3,0375	1,1	0,825	1,43
Rededge	3,88125	0,5	0,375	0,65
NIR	1,55625	0,5	0,375	0,65
<b>Kiefer</b>				
Blau	3,15	1,2	0,9	1,56
Grün	4,40625	2,9	2,175	3,77
Rot	3,09375	2,8	2,1	3,64
Rededge	10,66875	12,8	9,6	16,64
NIR	21,31875	23,2	17,4	30,16
<b>Wiese</b>				
Blau	2,9125	4,5	3,375	5,85
Grün	8,65	7,7	5,775	10,01
Rot	3,8625	6,2	4,65	8,06
Rededge	23,775	20	15	26
NIR	56,45	48	36	62,4



## 4.4 Vorverarbeitung der SAR-Satellitendaten

Die Vorverarbeitung der TerraSAR-X Daten wird anhand der GAMMA SAR and Interferometrie Software von GAMMA Remote Sensing (GAMMA, 2017) durchgeführt. Für die Vorverarbeitung der Sentinel-1 Daten wird die ESA SNAP Toolbox (ESA, 2018C) verwendet.

Als Eingangsdaten dienen die TerraSAR-X SLC beziehungsweise Sentinel-1 GRD Daten und ein SRTM-DGM. Die TerraSAR-X Daten werden, inklusive der *Header* Informationen, eingelesen und anhand der im *Header* vorhandenen Informationen radiometrisch korrigiert. Daraus ergeben sich die Intensitätsbilder in *Ground Range* Geometrie.

Mittels *Multilooking* werden nun die in *range* und *azimuth* Richtung unterschiedlichen räumlichen Auflösungen auf eine quadratische, räumliche Pixelauflösung gebracht und es entsteht ein *Multilook* Intensitätsbild.

Aus dem SRTM-DGM und dem Parameter-File des *Multilook* Intensitätsbild wird nun ein SAR Bild simuliert, welches der DGM Geometrie entspricht. Mittels einer Offset-Abschätzung und einer automatischen Kreuzkorrelation kann dann das georeferenzierte SAR Bild erstellt werden. Anschließend findet eine Konvertierung der linear-Werte in pseudo-unit Dezibel (dB) statt.

Die topographische Normalisierung verwendet eine Normalisierungsfaktorenkarte sowie eine lokale Einfallswinkelkarte basierend auf dem simulierten SAR-Bild um Einflüsse basierend auf dem Relief zu minimieren.

Am Ende dieses Prozesses steht das georeferenzierte, radiometrisch und topographisch korrigierte SAR Bild. Ein abschließend angewendeter *Speckle*-Filter verringert das Rauschen im Datensatz.

## 4.5 Klassifikationsziel

In diesem Kapitel werden die Klassen aufgezeigt, welche in dieser Arbeit erfasst werden. Um die Klassen der Kategorie der Biotoptypen zu definieren wurden die Daten der BNTK beziehungsweise BLNTK der Länder Sachsen respektive Mecklenburg-Vorpommerns herangezogen (Tabelle A 1 und Tabelle A 2). Anschließend werden die Klassen erfasst die in beiden Untersuchungsgebieten vorhanden sind und auf ihre visuelle Erkennbarkeit in den Satellitendaten hin überprüft. Lediglich die Klassen wurden ins Klassifikationsziel aufgenommen, welche in beiden Untersuchungsgebieten vorhanden und in den Daten anhand ihrer Größe, Breite, Form, spektralen und texturalen Eigenschaften visuell zu identifizieren sind. Einen Überblick über diese Klassen gibt Abbildung 6. Die detaillierte Klassenbeschreibung inklusive der Zuordnung, ob die jeweilige Klasse auf harten oder weichen Merkmalen beruht befindet sich im Folgenden.

### **Baumvegetation (weiche Merkmalsgruppe)**

Hauptgruppe für die Wald-, Baum-, Gebüsch- und Heckenklassen

### **Laubbaumvegetation (weiche Merkmalsgruppe)**


Zwischenklasse zwischen Hauptgruppe und Detailklassen. Beinhaltet nur Objekte mit 100 % Laubbeständen.

### **Nadelbaumvegetation (weiche Merkmalsgruppe)**

Zwischenklasse zwischen Hauptgruppe und Detailklassen. Beinhaltet nur Objekte mit 100 % Nadelbeständen


### **Waldobjekt (harte Merkmalsgruppe)**

Zwischenklasse basierend auf den BNTK-Objektgrenzen. Mindestens von 50 % Baumvegetation bedeckt und größer 2 ha.




### **Laubwald (harte Merkmalsgruppe)**

Über 90 % der Fläche des Waldobjektes (2 ha) setzt sich aus Laubbaumbeständen zusammen. Anders als in der BNTK-Klasse Laubwald (Reinbestand) beschrieben, muss die in dieser Arbeit verwendete Klasse nicht durch 90% einer Laubbaumart dominiert werden (LfULG, 2010).




### **Laubwald, gemischt (harte Merkmalsgruppe)**

Über 90 % der Fläche des Waldobjektes (2 ha) setzt sich aus Laubbaumbeständen zusammen, darüber hinaus sind mindestens 10 % Nadelbaumbestände im Waldobjekt vorhanden (LfULG, 2010).




### **Laubmischwald (harte Merkmalsgruppe)**

Zwischen 70 und 90 % des Waldobjektes (2 ha) setzt sich aus Laubbaumbeständen zusammen, darüber hinaus sind mindestens 10 %, aber maximal 30 % Nadelbaumbestände im Waldobjekt vorhanden (LfULG, 2010).



### **Mischwald (harte Merkmalsgruppe)**

Das Waldobjekt (2 ha) setzt sich aus etwa 50 % Laubwaldbeständen und 50 % Nadelwaldbeständen zusammen (LfULG, 2010).

**Nadelmischwald (harte Merkmalsgruppe)**

Zwischen 70 und 90 % des Waldobjektes (2 ha) setzt sich aus Nadelbaumbeständen zusammen, darüber hinaus sind mindestens 10 %, aber maximal 30 % Laubbaumbestände im Waldobjekt vorhanden (LfULG, 2010).

**Nadelwald (harte Merkmalsgruppe)**


Über 90 % der Fläche des Waldobjektes (2 ha) setzt sich aus Nadelbaumbeständen zusammen. Anders als in der BNTK-Klasse Nadelwald (Reinbestand) beschrieben, muss die in dieser Arbeit verwendete Klasse nicht durch 90% einer Baumart dominiert werden (LfULG, 2010).

**Landschaftselementobjekt (harte Merkmalsgruppe)**


Zwischenklasse basierend auf den BNTK-Objektgrenzen. Mindestens von 50 % Baumvegetation bedeckt und kleiner 2 ha.

**Feldgehölz / Baumgruppe (harte Merkmalsgruppe)**

Gehölzstreifen (ab 20 m Breite) oder kleine Gehölzgruppen mit einer Fläche zwischen 0.5 ha und 2 ha in der Agrarlandschaft und spontaner Gehölzaufwuchs oder kleinere "Restgehölze" auf nicht oder nicht mehr genutzten aufgelassenen Flächen innerhalb von Siedlungen. Bestehend aus Bäumen und Sträuchern verschiedener Altersstufen, Flächenausprägung wechselnd in allen Formen, je nach Gehölzart und Bestockungsgrad differentes Erscheinungsbild. (LfULG, 2010)

**Baumreihe (harte Merkmalsgruppe)**

Ein- oder zweireihige Baumreihe. Linienförmige, regelmäßig gepflanzte Baumbestände mit einer Länge von 100 m und einer Breite von < 20 m (LfULG, 2010).

**Einzelbaum (harte Merkmalsgruppe)**

Einzelbaum / Solitär mit einer Fläche unter 100 m<sup>2</sup> (LfULG, 2010).

**Hecke (harte Merkmalsgruppe)**

Linienförmig angelegte Gehölze mit Bäumen und Sträuchern. Starke Unterschiede in Höhe und Breite, unregelmäßiger Wechsel von gut erkennbaren Einzelkronen und zusammengewachsenen Gehölzen, meist keine Einzelpflanze erkennbar. Struktur bis ca. 20 m Breite, deutliche Höhenunterschiede. (LfULG, 2010) Geringere Objekthöhe im Vergleich zu den Baumreihen und Alleen.

**Gebüsch (harte Merkmalsgruppe)**

Laubgebüsche. Geringere Objekthöhe im Vergleich zu den Feldgehölzen und Baumgruppen, nicht linienartig (LfULG, 2010).

### Grün- und Graslandobjekt (weiche Merkmalsgruppe)

Zwischenklasse für die spektrale Abgrenzung der Grün- und Graslandklassen von den restlichen Klassen der Untergruppe.




### Feuchtgrünland (weiche Merkmalsgruppe)

Extensiv genutztes oder offengelassenes Grünland in feuchten bis nassen Senken und Mulden, in den Auen von Bächen und Flüssen bei hochanstehendem Grund-, Stau- oder Quellwasser (LfULG, 2010).



### Frisches Grünland (weiche Merkmalsgruppe)

Sowie artenreicheres, gedüngtes Dauergrünland frischer Mineralboden mit höherem Kräuteranteil. Brachliegende Flächen weisen weniger als 50 % Hochstauden auf. Dauergrünland oder Saatgrasland in intensiver Nutzung (LfULG, 2010).



### Trockengrünland (weiche Merkmalsgruppe)

Halbtrockenrasen kommen auf mittelgründigen, basenreichen Lehm- und Kalkverwitterungsböden vor beziehungsweise als weitgehend geschlossene, niedrige, blütenreiche Rasen auf verfestigten, etwas humosen Sandböden. Meist durch Beweidung entstanden (LUNG, 2010).



### Salzgrünland (weiche Merkmalsgruppe) (nur Rostock)

Salzgrünland auf wechselfeuchten bis feuchten Böden an Salzstellen des Binnenlandes sowie Salzwiesen der Ostseeküste werden entscheidend durch Salz- beziehungsweise Brackwasserüberflutungen geprägt. Häufig handelt es sich jedoch um Küstenüberflutungsmoore mit ehemals torfbildenden, salzbeeinflussten Röhrichten, deren Niveau wenig über der Mittelwasserlinie liegt. Charakteristisch sind gewundene Priele und Röten, die durch fließendes (Priele) und zurückbleibendes (Röten) Salzwasser bei Überflutungen entstehen (LUNG, 2010).



### Sümpfe und Moore / Ruderal- und Staudenfluren

Sümpfe sind von Sumpfpflanzen dominierte Lebensräume auf meist nährstoffreichen mineralischen sowie an moorigen Nassböden, oft mit offenem Wasserflächen (vgl. BUDER 1992).


Von Hochstauden beherrschte Flächen feuchter bis nasser Standorte an Ufern der Fließgewässer und Altwässer oder Brachestadien von Nasswiesen.

Von Stauden geprägte Flächen trockenwarmer Standorte, meist schmale Säume an südexponierten Wald- und Gebüschrändern oder trockenen Waldgrenzstandorten, häufig in Kontakt mit Laubwäldern und Gebüschen trockenwarmer Standorte oder Halbtrockenrasen (LUG, 2003).



### Acker (weiche Merkmalsgruppe)

Intensiv landwirtschaftlich genutzte Flächen ohne Unterscheidung der angebauten Frucht, mit oder ohne Ackerwildkrautvegetation, Bearbeitungsspuren sind erkennbar, einschließlich frisch eingesätem Saatgrasland (LfULG, 2010).



**Siedlung- und Infrastruktur (weiche Merkmalsgruppe)**


Zwischenklasse für die spektrale Abgrenzung der Siedlung- und Infrastrukturklassen von den restlichen Klassen der Untergruppe.

**Versiegelte Flächen (weiche Merkmalsgruppe)**


Zwischenklasse zwischen Hauptgruppe und Detailklassen. Klasse zur Abgrenzung des Offenen Bodens von den Klassen der versiegelten Flächen.

**Offener Boden (weiche Merkmalsgruppe)**

Anthropogen entstandene, der Rohstoffgewinnung dienende Gruben oder Böschungen (LfULG, 2010).

**Wohngebiet (harte Merkmalsgruppe)**

Mehrgeschossige (drei und mehr), verdichtete oder halboffene, meist überwiegend dem Wohnen dienende Bebauung in Blockrand- oder Zeilenbauweise, mäßige bis starke Versiegelung (25-85%) sowie aufgelockerte, überwiegend dem Wohnen dienende Bebauung, ein- bis maximal dreigeschossige Bauweise, als individuelle Einzelhausbebauung, vereinheitlichte Einzel- und Reihenhausbauweise. Hoher Anteil an privat genutzten Grünflächen, als Gartenflächen (Hausgärten) mit unterschiedlich dichtem Baumbestand, einschl. Wohnstraßen und Begleitgrün. Versiegelungsgrad meist 25-50%. LUNG (2010). Sowie aufgelockerte, vor allem dem Wohnen dienende mehr- bis vielgeschossige Bebauung mit punktförmiger oder längsgestreckter Bauform. Hoher Anteil nicht überbauter Fläche, als Freifläche, Grünfläche mit hohem Anteil an Abstandsgrün und Scherrasen, kleineren Spielflächen sowie Verkehrsflächen und Parkplätzen, z.T. mit Garagen (LUNG, 2010)

**Mischgebiet, Industrie- und/oder Gewerbegebiet (harte Merkmalsgruppe)**


Historische Stadtkerne mit zusammenhängend erhaltener, alter Bausubstanz oder Stadtbereiche, Stadtkerne mit sehr hohem Anteil an Handels- und Dienstleistungsunternehmen, öffentlichen Gebäuden, Parkhäusern und Parkplätzen, Fußgänger- und Einkaufszonen. Meist sehr geringer Grünflächenanteil. Versiegelungsgrad 60-100%. Sowie dörfliche Siedlungsflächen (z.B. Dorfkernbereiche) mit dorftypischen Bebauungsformen, wie z.B. landwirtschaftlich geprägten Wohn- und Wirtschaftsgebäuden, Ställen, Handels- und Dienstleistungsanwesen, Kirchen sowie kleineren hausnahen Garten- und Grünlandflächen.




Industrieflächen (einschl. Schwerindustrie, Kraftwerke, Müllverbrennungsanlagen) mit hohem Anteil an technischem Hochbau sowie mit Lager- und Produktionshallen, zugeordneten Verwaltungs- und Bürogebäuden. Einschließlich Lagerplätzen und Restflächen mit Ruderalvegetation

Gewerbe- und Dienstleistungsflächen (einschl. Einkaufszentren) sowie gewerbliche Sondernutzungen, wie Verwaltungskomplexe, Gelände größerer Bildungseinrichtungen, Kurheime und -kliniken mit dazugehörigen Verwaltungs- und Bürogebäuden, Lagerhallen, Lagerflächen und Abstandsgrün (LfULG, 2010).



**Verkehrsflächen**


Kommunale -, Land-, Bundesstraßen und Autobahnen sowie Schienenverkehrsflächen, Bahnbetriebsgelände, -werke, Bahnwirtschaftsgebäude sowie Bahnhöfe mit Begleitgrün und Restflächen mit Ruderalvegetation (LfULG, 2010).

**Gewässer (weiche Merkmalsgruppe)**

Zwischenklasse für die spektrale Abgrenzung der Gewässerklassen von den restlichen Klassen der Untergruppe.

**Fluss**

Naturnahes Fließgewässer mit durchschnittlichen Flussbreiten über 5 Meter (LfULG, 2010).


**Kleingewässer**

Natürlich oder anthropogen (sekundär) entstandene Kleingewässer, Tümpel oder Wasseransammlungen in feuchten Niederungen, in Ackersenken oder am Rand von größeren Gewässern bis zu einer Größe von 1 ha (LfULG, 2010).

**See**

Natürlich oder anthropogen (sekundär) entstandene Stillgewässer ab einer Größe von 1 ha (LfULG, 2010).

Abbildung 6: Klassifikationsziel (Hauptgruppe (blau), Untergruppe (grün) und Detailklassen (orange)).



# 5 Wissensbasis und Methoden

*„Given a number of features, how can one select the most important of them so as to reduce their number and at the same time retain as much as possible of their class discriminatory information?“*

Theodoridis S. & Koutroubas K. (2009): Pattern Recognition, 4th Edition. Academic Press (2009).

In diesem Kapitel werden die verwendeten Methoden und Merkmale, unterteilt in die Erzeugung der Wissensbasis, den Klassifikationsansatz und die Methodik zur Merkmalsauswahl, dargestellt.

Um erfolgreich ein Klassifikationsziel zu erreichen dient die in Abbildung 7 dargestellte Prozesskette als Grundlage. Die dargestellte Prozesskette ist in vier wesentliche Schritte unterteilt. Der erste Schritt ist die Merkmalsgenerierung. Bei der Merkmalsgenerierung werden aus den, für die Fragestellung vorliegenden Daten Merkmale, auch als *Features* bezeichnet, erzeugt. Betrachtet man die Literatur zu verschiedenen Klassifikationsfragestellungen ergibt sich eine Vielzahl von möglichen Merkmalen welche aus den vorliegenden Daten erzeugt werden können. Einen detaillierten Überblick über die potenziellen Merkmale sowie die tatsächlich für die vorliegende Fragestellung erzeugten Merkmale gibt Kapitel 5.1. Der wichtigste Schritt in der Prozesskette, die Merkmalsauswahl wird in Kapitel 5.3 behandelt. Zunächst wird die Auswahl der Trennbarkeitsmerkmale dargestellt, dann die Vorverarbeitung gefolgt von der Beschreibung des Merkmalsrankings sowie der Merkmalsreduktion. In Kapitel 5.2 wird der Klassifikationsansatz, inklusive der verwendeten Segmentierung, Klassifikationsmethode, Klassifikationsablauf, der Erstellung des Häufigkeitsdatensatz, der Klassenzusammenlegung, der Übertragbarkeit und der Genauigkeitsanalyse detailliert beschrieben. Im Kapitel 5.4 werden abschließend die möglichen Synergieeffekte und die Methodik zur Evaluation der Synergie dargestellt.




Abbildung 7: Grundlegende Prozesskette zur Schaffung der Wissensbasis und der Klassifikation (verändert nach THEODORIDIS & KOUTROUMBAS, 2009).



## 5.1 Erzeugung der Wissensbasis

Die Wissensbasis und somit die Auswahl der für die Klassifikation verwendeten Merkmale ist essentiell für den Erfolg der Klassifikation. Werden in der Klassifikation Merkmale verwendet, welche redundante Informationen enthalten und die Klassen nicht optimal voneinander unterscheiden können, sinkt die Genauigkeit der resultierenden Klassifikation. Abbildung 8 zeigt beispielhaft den Merkmalsraum zweier Klassen und zweier Merkmale, welche die Klassen beziehungsweise Cluster im Merkmalsraum, unterschiedlich gut trennen. Während sich die Klassen mittels des Merkmals repräsentiert durch Vektors  $a_1$  nicht trennen lassen, ist eine Trennung anhand des Merkmals, repräsentiert durch den Vektor  $a_0$  möglich.




Abbildung 8: Trennbarkeit zweier Klassen anhand zweier Merkmale (THEODORIDIS & KOUTROUMBAS, 2009).

Generell werden die Merkmale im weiteren Verlauf der Arbeit in *weiche* und *harte* Merkmale unterteilt. Die *weichen* Merkmale zeichnen sich dadurch aus, dass sie anhand der Merkmalsauswahl für jede Klasse und jeden Datensatz ermittelt und die Schwellwerte durch den Klassifikator definiert werden. Die *harten* Merkmale werden über die Klassenbeschreibung im Vorhinein fest definiert und unverändert in allen Datensätzen verwendet. Beispiele für *harte* Merkmale sind geometrische Merkmale wie die Objekthöhe oder die Objektbreite und relationale Merkmale wie die Anteile verschiedener Klassen an einem Objekt.

### 5.1.1 Potenzielle Merkmale

Tabelle 9 gibt einen Überblick über Merkmalskategorien, welche in der Literatur zur Klassifikation von Biotoptypen und der Landnutzung beziehungsweise der Landbedeckung verwendet werden. Im Allgemeinen kann festgehalten werden, dass in den meisten Untersuchungen nicht nur eine Kategorie an Merkmalen verwendet wird, sondern oftmals eine kombinierte Nutzung verschiedener Merkmale zur Anwendung kommt.

Untersuchungen in denen ausschließlich die reinen spektralen Informationen, welche direkt aus den Satellitendaten extrahiert werden können, als Klassifikationsgrundlage dienen sind selten. Beispiele für die Verwendung von ausschließlich spektralen Informationen sind THEAU ET AL., 2005, VARELA ET AL., 2008 und HAEST ET AL., 2017.

THEAU ET AL., 2005 verwenden eine pixel-basierte *Spectral mixture analysis* (SMA) um neun Klassen mit dem Hauptaugenmerk auf Flechtenvegetation aus Landsat TM Daten zu extrahieren. Hierbei stellte sich jedoch heraus, dass monotemporale, spektrale Informationen nicht ausreichen um die gewünschte Klassentiefe zu erreichen. VARELA ET AL., 2008 vergleichen einen objekt-basierten und einen pixel-basierten Klassifikationsansatz zur Ableitung von 8, 9 und 15 Biotoptypen anhand der Landsat TM

Kanäle. Auch bei dieser Untersuchung kann anhand der spektralen Merkmale lediglich eine Gesamtgenauigkeit (*Overall Accuracy*) von 0.49, 0.62 und 0.66 (15, 9 und 8 Biotoptypen) sowie 0.59, 0.67 und 0.69 (15, 9 und 8 Biotoptypen) für die pixel-basierte respektive objekt-basierte Klassifikation erreicht werden.

Andere Untersuchungen (BARRETT ET AL., 2016, CONCHEDDA ET AL., 2008, DUSSEUX ET AL., 2014, FRICK, 2006, GÄHLER, 2006, HYDE ET AL., 2006, HONG ET AL., 2015, LUCAS ET AL., 2007, LUCAS ET AL., 2011, SCHULTZ ET AL., 2015) mit dem Ziel der Ableitung von Biotoptypenklassen verwenden zusätzlich zu den reinen spektralen Merkmalen Vegetationsindices. Der wohl am häufigsten in diesem Zusammenhang verwendete Vegetationsindex ist der *Normalized Difference Vegetation Index* (NDVI). In allen in der Tabelle 9 unter Vegetationsindices dargestellten Veröffentlichungen wird der NDVI als Klassifikationsmerkmal verwendet. Hierbei fällt auf, dass in den meisten Untersuchungen keine anderen Vegetationsindices verwendet werden beziehungsweise die Eignung des NDVI im Hinblick auf die angestrebten Klassen überprüft wird.

Tabelle 9: Verwendete Merkmale in der Biotoptypen- und Landnutzungskartierung.

Merkmalsgruppen	Veröffentlichungen
Spektrale Informationen	BARRETT ET AL., 2016, DURIC ET AL., 2014, FRICK, 2006, GÄHLER, 2006, KIM & YEOM, 2014, LUCAS ET AL., 2007, HAEST ET AL., 2017, HONG ET AL., 2015, O'CONNELL ET AL., 2015, SCHULTZ ET AL., 2015, STUMPF & KERLE, 2011, THEAU ET AL., 2005, VARELA ET AL., 2008
Vegetationsindices	BARRETT ET AL., 2016, CONCHEDDA ET AL., 2008, DUSSEUX ET AL., 2014, FRICK, 2006, GÄHLER, 2006, HYDE ET AL., 2006, HONG ET AL., 2015, LUCAS ET AL., 2007, LUCAS ET AL., 2011, SCHULTZ ET AL., 2015
Texturmaße	BARGIEL, 2013, BARRETT ET AL., 2016, BERBEROGLU ET AL., 2007, DURIC ET AL., 2014, ESTES ET AL., 2008, FRICK, 2006, GÄHLER, 2006, KIM & YEOM, 2014, LABA ET AL., 2010, LI ET AL., 2016, MAXWELL ET AL., 2015, O'CONNELL ET AL., 2015, SCHULTZ ET AL., 2015, STUMPF & KERLE, 2011
Spektrale Transformationen	PASHER ET AL., 2007, STICKLER & SOUTHWORTH, 2008
Relationale Merkmale	BUCHOW ET AL., 2007, CONCHEDDA ET AL., 2008, O'CONNELL ET AL., 2015
Geometrische Merkmale inklusive Objekthöheninformationen	BUCHOW ET AL., 2007, BUCHOW, 2009, DALPONTE ET AL., 2008, DURIC ET AL., 2014, HYDE ET AL., 2006, KE ET AL., 2010, KIM ET AL., 2009, MAXWELL ET AL., 2015, O'CONNELL ET AL., 2015, PETERS ET AL., 2011, SCHULTZ ET AL., 2015, STUMPF & KERLE, 2011, WASER ET AL., 2006, ZLINSZKY ET AL., 2014
SAR Merkmale	BARGIEL, 2013, DUSSEUX ET AL., 2014, HONG ET AL., 2015, HYDE ET AL., 2006, MCNAIRN ET AL., 2009, PETERS ET AL., 2011, TAFT ET AL., 2003, ULLMANN ET AL. 2014, WASKE, B. & BRAUN, M., 2009
Multi-temporale Merkmale	BARRETT ET AL., 2014, BUCK ET AL., 2015, GIMENEZ ET AL., 2017, LUCAS ET AL., 2007, LUCAS ET AL., 2011, MEDDENS ET AL., 2013, WANG ET AL., 2018

Texturmaße werden in verschiedenen Studien zur Klassifikation von Vegetation (BARGIEL, 2013, BARRETT ET AL., 2016, BERBEROGLU ET AL., 2007, ESTES ET AL., 2008, FRICK, 2006, GÄHLER, 2006, KIM & YEOM, 2014, LABA ET AL., 2010, LI ET AL., 2016, MAXWELL ET AL., 2015, O'CONNELL ET AL., 2015, SCHULTZ ET AL., 2015, STUMPF & KERLE, 2011) und darüber hinaus zur Modellierung der Vegetationsstruktur (ESTES ET AL., 2008, STICKLER & SOUTHWORTH, 2008) herangezogen. Bei der Auswertung der Veröffentlichungen zeigen sich ähnliche Ergebnisse bei der Eignung der Textur als zusätzliches Klassifikationsmerkmal. LABA, 2010 untersuchen die Eignung der Varianz zur Klassifikation von elf naturnahen Landbedeckungsklassen unter Verwendung von IKONOS-Daten und eines pixel- und eines objekt-basierten *Maximum Likelihood* Klassifikators. Bei der Bewertung der pixel-basierten Klassifikation inklusive Textur zeigt sich, dass die Klassifikationsgenauigkeit gegenüber der Verwendung der reinen spektralen Merkmale von 76.2 % auf 45 % *Overall Accuracy* zurückgeht. Bei der objekt-basierten Klassifikation führt die Verwendung der Textur lediglich zu minimalen Änderungen in den Genauigkeiten. Auch WANG ET AL., 2004 bestätigen, dass bei der Trennung verschiedener Baumarten unter Einbeziehung der Textur (Standardabweichung und Entropie) abgeleitet aus IKONOS

und Quickbird-Daten keine Verbesserung der Klassifikationsgenauigkeiten erreicht werden kann. BERBEROGLU ET AL., 2007 halten ebenfalls fest, dass bei der Klassifikation von Vegetation unter Verwendung der Textur (Standardabweichung, Kontrast und *Angular Second Moment*) keine Verbesserung der Gesamtgenauigkeit erreicht werden kann. Dagegen zeigen BARGIEL, 2013 und O'CONNELL ET AL., 2015 gesteigerte Klassifikationsgenauigkeiten bei der Hinzunahme von Texturmaßen. Um diese Ergebnisse zu evaluieren werden Texturmaße generiert und anschließend auf ihre Klassentrennbarkeit hin untersucht.

Als weitere Merkmalsgrundlage werden in der Literatur (PASHER ET AL., 2007, STICKLER & SOUTHWORTH, 2008, WEIERS ET AL., 2004) Verfahren der multivariaten Statistik genannt. Diese Verfahren dienen dazu eine Anzahl an Variablen, z.B. die spektralen Bänder, durch wenige, aussagekräftige Linearkombinationen auszudrücken.

Geometrische und relationale Merkmale als Klassifikationsgrundlage für die Ableitung von Biotoptypen finden hauptsächlich, aber nicht ausschließlich im urbanen Bereich Anwendung (BUCHOW ET AL., 2007, BUCHOW, 2009, CONCHEDDA ET AL., 2008, DALPONTE ET AL., 2008, HYDE ET AL., 2006, KE ET AL., 2010, KIM ET AL., 2009, MAXWELL ET AL., 2015, O'CONNELL ET AL., 2015, PETERS ET AL., 2011, SCHULTZ ET AL., 2015, STUMPF & KERLE, 2011, WASER ET AL., 2006, ZLINSZKY ET AL., 2014). Unter geometrischen Merkmalen werden hierbei z.B. die Fläche oder das Länge-Breite-Verhältnis eines Objektes verstanden. In diese Merkmalsgruppe fallen auch die Objekthöhe als geometrisches Merkmal und Nachbarschafts- und Ebenenbeziehungen zwischen Klassen als relationale Merkmale.

Ein multi-temporaler Ansatz wie in LUCAS ET AL., 2007 und LUCAS ET AL., 2011 dargestellt, kann aufgrund der unzureichenden Datenlage der TerraSAR-X und RapidEye Abdeckungen für diese Datenquellen nicht verfolgt werden. Für die Sentinel-1 und Sentinel-2 Daten und deren hoher zeitlicher Abdeckung werden multi-temporale Merkmale erzeugt.

Der Einsatz von SAR-Merkmalen in der Biotoptypenkartierung fand bis dato kaum Anwendung. Jedoch zeigte die Verwendung von SAR-Rückstreuung und Merkmalen generiert aus den SAR-Informationen ein hohes Potenzial der Ableitung von Landbedeckung und Feldfrüchten mittels multi-temporalen Klassifikation (BARGIEL, 2013, DUSSEUX ET AL., 2014, HONG ET AL., 2015, HYDE ET AL., 2006, MCNAIRN ET AL., 2009, PETERS ET AL., 2011, TAFT ET AL., 2003, ULLMANN ET AL. 2014, WASKE, B. & BRAUN, M., 2009). Aus den vorliegenden SAR-Daten werden Rückstreuwerte und Ratio generiert und für die Klassifikation herangezogen.

### 5.1.2 Merkmalsbeschreibung

In diesem Kapitel werden die für die folgenden Analysen erstellten Merkmale beschrieben. Die erste Merkmalskategorie, die spektralen Merkmalen umfassen: Reflektanzen der Zeitschritte pro Band (Wertebereich:  $[0,1]$ ), normalisierte, maximale Differenz der Helligkeit eines Objektes zu allen anderen Objekten über alle Bänder (Wertebereich:  $[0,1]$ ) und Helligkeit eines Objektes im Verhältnis zu allen anderen Objekten über alle Bänder (Brightness) (Wertebereich:  $[0, \infty]$ ). Aus den spektralen Merkmalen, welche direkt in die weiteren Analysen einfließen, werden Vegetationsindices berechnet.

Aus der Vielzahl der bis dato entwickelten Vegetationsindices werden sowohl sehr einfache Ratio wie der *Ratio Vegetation Index* (RVI) als auch komplexere, empirisch erweiterte Ratio wie der *Global Environment Monitoring Index* (GEMI) abgeleitet. Einer der einfachsten Ratio ist der *Difference Vegetation Index* (DVI) (RICHARDSON & WIEGAND, 1977). Der DVI ergibt sich aus einer Division des roten ( $p_r$ ) Wellenlängenbereich vom nahen infraroten ( $p_{nir}$ ) Wellenlängenbereich. Eine nur leicht abgewandelte Ratio ist der *Ratio Vegetation Index* (RVI) (BIRTH & G. MCVEY, 1968) oder auch *Simple Ratio* (SR) (PEARSON & MILLER, 1972), im Folgenden als RVI bezeichnet. Der RVI wird gebildet aus den Bändern im roten ( $p_r$ ) und nahen infraroten ( $p_{nir}$ ) Wellenlängenbereich. Eine einfache Abwandlung des RVI ist der *Green Ratio*

*Vegetation Index* (GRVI) (SRIPADA ET AL., 2006), hierbei wird im RVI das rote ( $p_r$ ) Band durch das Band aus dem grünen ( $p_g$ ) Wellenlängenbereich ausgetauscht. Einer der am häufigsten verwendeten Vegetationsindices, der *Normalized Difference Vegetation Index* (NDVI) ist eine Ratio gebildet aus den Bändern im roten ( $p_r$ ) und nahen infraroten ( $p_{nir}$ ) Wellenlängenbereich und besitzt eine hohe Sensitivität im Bereich der vitalen Vegetation (TUCKER, 1979). Zwei Variationen des NDVIs sind der *Normalized Difference Green Index* (NDGI) (TUCKER, 1979) und der *Green Normalized Difference Vegetation Index* GNDVI (GITELSON ET AL., 1996). Bei diesen Indices wird die rote ( $p_r$ ) respektive nahen infrarote ( $p_{nir}$ ) Information durch das grüne ( $p_g$ ) Band ausgetauscht.

Der *Soil Adjusted Vegetation Index* (SAVI) wurde 1988 von Huete entwickelt. Hierbei wurde versucht den Einfluss des Bodens auf den Vegetationsindex zu minimieren.

$$SAVI = (1 + L) * \frac{(p_{nir} - p_r)}{(p_{nir} + p_r + L)}$$

Wobei L nach HUETE (1988) einen Wert von  $L = 1$  bei einer geringen Vegetationsdicht,  $L = 0.5$  bei einer mittleren Vegetationsdichte und  $L = 0.25$  bei einer dichten Vegetation annehmen soll.

Der *Enhanced Vegetation Index* (EVI) basiert auf dem SAVI und wurde entwickelt, um die Sensitivität gegenüber Regionen mit hoher Biomasse zu verbessern und eine verbesserte Vegetationsbeobachtung durch die Entkopplung des Vegetationssignals vom Bodensignal und der Reduktion der atmosphärischen Effekte zu ermöglichen (HUETE ET AL., 1994, HUETE ET AL., 2002). Zusätzlich zu den in den vorangegangenen Indices verwendeten Bändern aus den roten ( $p_r$ ) und nahen infraroten ( $p_{nir}$ ) Wellenlängenbereichen, fließen in die Berechnung des EVI die Informationen aus dem blauen ( $p_b$ ) Wellenlängenbereich mit ein.

$$EVI = G * \frac{(p_{nir} - p_r)}{(p_{nir} + C_1 * p_r - C_2 * p_b + L)}$$

Wobei nach HUETE ET AL., 2002  $L=1$  bei geringer Vegetationsdicht,  $L = 0.5$  bei mittlerer Vegetationsdichte und  $L = 0.25$  bei dichter Vegetation,  $C_1 = 6$ ,  $C_2 = 7.5$ , und  $G$  (gain factor) = 2.5.

Ein weiterer eingesetzter Index ist der von PINTY & VERSTRAETE (1992) entwickelte *Global Environmental Monitoring Index* (GEMI). Der GEMI ist ein nichtlinearer Index aus den Bändern im roten ( $p_r$ ) und nahen infraroten ( $p_{nir}$ ) Bereich, ebenfalls konzipiert um Atmosphäreneffekte und Effekte resultierend aus dem Vegetationshintergrund (Boden) zu minimieren. Der Index ist definiert als:

$$GEMI = \eta(1 - 0.25\eta - \frac{(p_r - 0.125)}{(1 - p_r)})$$

Wobei

$$\eta = \frac{(2(p_{nir}^2 - p_r^2) + 1.5p_{nir} + 0.5p_r)}{(p_{nir} + p_r + 0.5)}$$

Die Vegetationsindices werden für alle Zeitschritte der optischen Daten berechnet.

Weiterhin wird aus den optischen und SAR-Daten die Textur nach HARALICK, 1979 beziehungsweise HARALICK ET AL., 1973 abgeleitet. Unter Textur werden allgemein die Oberflächenstrukturen verstanden, welche sich im Bild durch Grauwertsprünge zeigen (HILDEBRANDT, 1996). Die Texturanalyse untersucht die Grauwertveränderung zwischen einem Pixel und seinen Nachbarn innerhalb einer vorgegebenen Fläche. Dies geschieht durch ein sich über das Bild bewegendes *Fenster*,

auch als *Kernel* oder *Window* bezeichnet, mit einer vordefinierten Größe. In dem definierten Fenster wird das Verhältnis des mittleren Pixels zu den umgebenden Pixeln berechnet. Hierbei finden je nach Texturmaß z.B. die mittlere euklidische Distanz oder die Varianz Anwendung. Die Größe des Fensters wird dabei an die vorliegenden Objekte beziehungsweise deren Grundtexturen angepasst (GÄHLER, 2006). Hierbei soll die Fenstergröße ein Kompromiss zwischen der Bereitstellung genügend räumlicher Information für die Differenzierung der Textur und der Abgrenzung der Überlappung verschiedener Texturen darstellen (ULABY ET AL., 1986).

Die abgeleiteten Texturmaße berechnet für alle Zeitschritte der RapidEye-Daten, der Sentinel-1- und Sentinel-2-Daten sowie der TerraSAR-X-Daten umfassen:

- *Angular Second Moment*
  - Wertebereich [0,1]
- *Contrast*
  - Wertebereich [0, 65025]
- *Correlation*
  - Wertebereich [0,1]
- *Dissimilarity*
  - Wertebereich [0,255]
- *Entropy*
  - Wertebereich [0, 10404]
- *Homogeneity*
  - Wertebereich [0,1]
- *Mean*
  - Wertebereich [0,255]
- *Varianz*
  - Wertebereich [0,255]

Die Grundlagen zur Berechnung basieren auf HARALICK, 1973, HARALICK ET AL., 1979 und CONOR & HARLOW, 1980.

Als spektrale Transformationsmethoden finden die *Principal Component Analyse* (PCA), *Minimum Noise Fraction Transformation* (MNF) und die *Independent Component Analyse* (ICA) Anwendung. Die PCA transformiert die korrelierenden spektralen Bänder so, dass sie de-korreliert und anhand ihrer Varianz absteigend angeordnet werden. Das letzte Band enthält hauptsächlich Rauschen. Die PCA separiert das Rauschen von wertvollen Informationen und kann die Merkmalsanzahl reduzieren (GALAL & HASAN, 2012).

Die MNF bezieht bei der Transformation im Gegensatz zur PCA zusätzlich den *signal-to-noise ratio* (SNR) mit in die Berechnung ein. Der SNR vergleicht den Grad des gewünschten Signals mit dem Grad des Hintergrundrauschens. Die MNF besteht aus zwei Schritte:

- 1) Transformation anhand einer Kovarianzmatrix des Rauschens, wobei nur Daten transformiert werden, welche eine einheitliche Varianz im Rauschen und keine Korrelation zwischen den Bändern besitzen und
- 2) einer PC Transformation.

Die entstehenden Bilder mit hohen Eigenvalues beinhalten die nutzbaren Informationen, die mit Werten nahe eins das Rauschen. Die Hauptproblematik bei dieser Methode ist allerdings die Bestimmung des Sensorrauschens (GALAL & HASAN, 2012).

Die ICA transformiert die Eingangsdaten unter der Annahme, dass in jedem Band unabhängige lineare Komponenten versteckt sind. Durch einen linearen Entmischungsalgorithmus sollen diese Komponenten nun wieder sichtbar gemacht werden. Hierbei wird davon ausgegangen, dass alle Komponenten statistisch unabhängig und nicht normalverteilt sind (GALAL & HASAN, 2012). Die abgeleiteten Transformationsmaße umfassen: MNF für alle Zeitschritte der RapidEye-Daten sowie

Sentinel-2-Daten, ICA für alle Zeitschritte der RapidEye-Daten sowie Sentinel-2-Daten und PCA für alle Zeitschritte der RapidEye-Daten sowie Sentinel-2-Daten.

Die erzeugten geometrischen Merkmale basieren auf Objekten generiert mittels einer Segmentierung (Kapitel 5.2.1). Die geometrischen Merkmale umfassen:

- Objekthöhe
  - basierend auf dem nDSM
  - Wertebereich: [0, maximale Höhe im Untersuchungsgebiet]
- Fläche eines Objektes
  - Wertebereich: [0, Bildfläche]
- Kantenlänge der umschließenden Kanten eines Objektes
  - Wertebereich: [0,  $\infty$ ]
- Länge eines Objektes
  - Wertebereich: [0,  $\infty$ ]
- Dicke eines Objektes
  - Wertebereich: [0,  $\infty$ ]
- Breite eines Objektes
  - Wertebereich: [0,  $\infty$ ]
- Länge/Dicke-Verhältnis eines Objektes
  - Wertebereich: [0,  $\infty$ ]
- Länge/Breite-Verhältnis eines Objektes
  - Wertebereich: [0,  $\infty$ ]
- Asymmetrie
  - relative Länge eines Objektes zu einem regulären Polygon (Ellipse)
  - Wertebereich: [0,1]
- *Border Index*
  - gibt Auskunft über die Struktur eines Objektes
  - berechnet anhand des kleinsten das Objekt umschließenden Rechteckes und der Kantenlänge des Objektes
  - Wertebereich: [1,  $\infty$ ], 1 = ideal.
- Kompaktheit
  - ist die Summe aus Länge und Breite geteilt durch die Fläche des Objektes (Anzahl der Pixel)
  - Wertebereich: [1,  $\infty$ ], 1 = ideal.
- Dichte
  - ist die Anzahl der Pixel eines Objektes geteilt durch dessen Radius
  - Wertebereich [0, abhängig von den Objektformen]
- *Elliptic Fit*
  - berechnet die Übereinstimmung des Objektes mit einer Ellipse gleicher Fläche
  - verglichen werden die Flächen innerhalb und außerhalb der Ellipse
  - Wertebereich: [0,1]
  - 0 bedeutet keine Übereinstimmung, 1 komplette Übereinstimmung
- Hauptrichtung
  - ist die Richtung des größeren, zweier Eigenvektoren berechnet auf der Grundlage einer Kovarianzmatrix der räumlichen Verteilung des Objektes
  - Wertebereich: [0,180]
- *Rectangular Fit*
  - berechnet die Übereinstimmung des Objektes mit einem Rechteck gleicher Fläche, verglichen werden die Flächen innerhalb und außerhalb des Rechtecks
  - Wertebereich: [0,1]
  - 0 bedeutet keine Übereinstimmung, 1 komplette Übereinstimmung
- *Roundness*

- beschreibt den Unterschied zwischen dem Radius einer Ellipse welche komplett innerhalb des Objektes liegt und einer Ellipse, welche das Objekt komplett umschließt
- Wertebereich:  $[0, \infty]$ , 0 = ideal.
- Shape index
  - beschreibt die Glätte eines Objektes
  - wird berechnet anhand der Kantenlänge des Objektes geteilt durch die Wurzel aus der vierfachen Fläche
  - Wertebereich:  $[1, \infty]$ , 1 = ideal.

Die für die Sentinel-1 und Sentinel-2 Daten erzeugten multi-temporalen Merkmale basierend auf allen mono-temporalen Merkmalen beinhalten:

- den multi-temporalen Mittelwert je Kanal,
- die multi-temporale Varianz je Kanal,
- die multi-temporale Standardabweichung je Kanal,
- die multi-temporale 5 % Perzentile je Kanal und
- die multi-temporale 95 % Perzentile je Kanal.

### 5.1.3 Erwartete Merkmale der Biotoptypen

Die in Kapitel 4.5 vorgestellten und zu kartierenden Klassen, für die Merkmalsausprägungen anhand der Literatur oder aus Datenbanken vorhanden sind, werden in diesem Kapitel dahingehend betrachtet, wie diese Merkmalsausprägungen sich auszeichnen.

Die spektralen Merkmale inklusiver der Vegetationsindices bilden eine der Merkmalsgruppen. Diese Merkmalsgruppe kann direkt aus den vorverarbeiteten optischen Satellitendaten erzeugt werden. Die folgenden Spektren sind lokal mittels Spektrometer gemessen, die Werte im Satellitenbild jedoch durch verschiedenste Faktoren beeinflusst. Diese Faktoren können Einflüsse aus der Atmosphäre, welche selbst durch eine Atmosphärenkorrektur nicht komplett eliminiert werden, die räumliche und spektrale Auflösung des Sensors welche zur Mischpixeln im Bild führt, die Variation der Vegetation über die Saison und die Aufnahmegeometrie des Sensors sein. Die zugrundeliegenden Spektren basieren auf einer Datenbank des United States Geological Survey (USGS) (CLARK ET AL., 2007).

Betrachtet man die erste Gruppe der Biotoptypen (Kapitel 4.5), die *Baumvegetation*, im Hinblick auf die spektralen Eigenschaften, so muss zunächst einmal zwischen Bereichen mit Nadelbäumen und Laubbäumen unterschieden werden. Abbildung 9 zeigt typische Spektren für jeweils zwei Laubbaum- und Nadelbaumarten. Hierbei zeigen die Laubbaumarten in den Bereichen des blauen und roten Kanals der RapidEye Daten eine Reflexion zwischen 5.5 % - 6.8 % (Espe) und 9.6 % - 11 % (Eiche), im grünen Kanal im Bereich von 8.4 % - 12.5 % (Espe) und 11.8 % - 17 % (Eiche) Reflexion, wobei der durch den RapidEye Sensor abgedeckte Bereich von 40 nm und die damit verbundene Variation zu beachten sind. Für den rededge Kanal des RapidEye nimmt die Variation der hier gezeigten Spektren Werte von 6.5 % - 40 % (Espe) und 10 % - 54 % (Eiche) an, während der nahe Infrarotkanal wieder stabilere Werte von 47 % - 47.5 % (Espe) und 79 % - 85 % (Eiche) annimmt. Für die Nadelbäume (Kiefer und Fichte) liegen die Werte zwischen 1.4 % - 2.1 % (blauer Kanal), 1.7 % - 3.3 % (grüner Kanal), 1.9 % - 3.1 % (roter Kanal), 2.2 % - 10 % (rededge Kanal) und 11.5 % - 14 % (nahes Infrarot). Für die Vegetationsindices sind anhand der oben genannten Reflexionen, im Mittel Werte von 7.4 (Espe), 7.9 (Eiche), 4.2 (Kiefer) und 6.1 (Kiefer) für den RVI und 0.76 (Espe), 0.77 (Eiche), 0.61 (Kiefer) und 0.72 (Kiefer) für den NDVI zu erwarten. Somit kann davon ausgegangen werden, dass spektral Nadelbaumbestände von Laubbaumbeständen trennbar sind. Nichtsdestotrotz müssen spektrale Überlappungen mit anderen Biotoptypengruppen mit Vegetationsanteil erwartet werden. Eine spektrale Trennung der Landschaftselemente (Feldgehölz, Baumgruppe, Baumreihe, Dominanter Einzelbaum, Hecke sowie Gebüsch und Strauchgruppe) wird nicht angestrebt. Diese bilden Unterklassen zu den Laub- beziehungsweise Nadelbaumbereichen und werden anhand geometrischer

Merkmale separiert. Ähnlich verhält es sich mit den Waldmischklassen (Laubwald, Nadelwald, Laubmischwald, Nadelmischwald, Laubwald (gemischt), Nadelwald (gemischt) und Mischwald), welche auf Basis der BNTK-Grenzen aus den Klassen Laubbaumbestände und Nadelbaumbestände gebildet werden.

Die Biotoptypengruppe *Grünland* bildet, spektral betrachtet, eine anspruchsvolle Klassifikationsaufgabe. Dies liegt an der möglichen, hohen Varianz der Grünlandbereiche begründet in der Vielzahl der verschiedenen Pflanzenarten und Zustände. Hierzu zählt der anthropogene Einfluss (Beweidung, Mahd), die phänologische Phase, die Dichte des Bewuchses und das daraus resultierende Bodensignal sowie mögliche Überflutungen bei Salz- und Feuchtgrünland.




Abbildung 9: Typische Spektren für die Baumarten Espe (a), Eiche (b), Kiefer (c) und Fichte (d) (Quelle: CLARK ET AL., 2007).

Um große klasseninterne Variationen zu vermeiden wird angelehnt an die BNTK-Referenz zwischen Feuchtgrünland, Salzgrünland, Frischem Grünland und Trockengrünland unterschieden. Um eine spektrale Einordnung von Grünlandflächen vornehmen zu können sind in Abbildung 10 die Spektren (a) eines Grünlandes mit Anteilen von 90 % trockenem und 10 % vitalem Gras sowie (b) vitalem Gras dargestellt. Für das Mischspektrum aus 90 % trockenem und 10 % vitalem Gras liegen die Reflexionswerte zwischen 10,8 % - 18,5 % (blauer Kanal), 19,5 % - 24,7 % (grüner Kanal), 26,6 % - 29,2 % (roter Kanal), 29,2 % - 33,9 % (rededge Kanal) und 37,2 % - 39 % (nahes Infrarot), für das vitale Gras bei 3,1 % - 5 % (blauer Kanal), 6,4 % - 9,7 % (grüner Kanal), 5,3 % - 4,2 % (roter Kanal), 5 % - 41 % (rededge Kanal) und 66 % - 70,5 % (nahes Infrarot). Für die Vegetationsindices ergeben sich Werte von 1,4 (90/10 Gras) und 14,5 (vitales Gras) für den RVI sowie 0,16 (90/10 Gras) und 0,87 (vitales Gras) für den NDVI. Die Grünlandbereiche verfügen somit über eine sehr hohe Variation im Reflexionsverhalten, spektrale Überlappungen mit anderen Vegetationsbereichen müssen erwartet werden. BOCK ET AL.,



2005 bemerken hierzu, dass eine Trennung von „Grünland, semi-natürlichen Biotoptypen und bestandenen landwirtschaftlichen Flächen mittels einer Satellitenaufnahme nicht immer möglich ist“.

Die Biotoptypengruppe *Acker* kann ebenfalls nicht eindeutig spektral definiert werden. Dies liegt an der Vielzahl der möglichen Ausprägungen dieser Gruppe, welche von offenem Boden über Brachflächen mit sehr heterogenem und / oder spärlichem Bewuchs bis hin zu einer vielfältigen Vegetationsdeckung, bezüglich der Feldfrucht und Dichte der Vegetation, reichen kann. Da keine Referenz für die betrachteten Jahre vorliegt und Aussagen zu den Feldfrüchten, den Brachflächen und sonstigen unbestandenen Flächen nicht möglich ist, kann auch die spektrale Ausprägung nicht detailliert quantifiziert werden.




Abbildung 10: Typische Spektren für Grünland: 90 % trockenes und 10 % vitales Gras (a), vitales Gras (b) (Quelle: CLARK ET AL., 2007).




Abbildung 11: Typische Spektren für offene Wasserflächen (a) und offenem Boden (b) (Quelle: CLARK ET AL., 2007).

Für *Gewässer* ergibt sich ein wie in Abbildung 11 (a) gezeigtes Spektrum. Die erwarteten Werte der Reflexion liegen zwischen 2 % und 5 % für die Kanäle des RapidEye. Die Werte für den NDVI liegen im negativen Bereich und die für den RVI um 0. In Fällen mit Signal vom Grund, Vegetationsauflage oder einem hohen Anteil an Schwebstoffen variiert das Spektrum und zeigt typischer Weise höhere Reflexionswerte.

Für *Moor- und Sumpfbereiche* ist durch ihre facettenreichen Erscheinungsformen zu erwarten, dass sie nicht spektral eindeutig zugeordnet werden können, sondern je nach räumlicher Auflösung der Fernerkundungsdaten ein Mischsignal aus Wasserflächen, Baum- und Heckenbeständen sowie typischer Moor- und Sumpfvvegetation repräsentieren. In dieser Biotoptypengruppe spielt die räumliche Auflösung eine entscheidende Rolle. Mit steigender räumlicher Auflösung können die einzelnen Bestandteile der Moor- und Sumpfbereiche getrennt kartiert werden und anschließend in der Biotoptypengruppe Moor und Sumpf zusammengeführt werden.

Bereiche des *offenen Bodens* sind in den verwendeten Untersuchungsgebieten nur selten vegetationsfrei. Das in Abbildung 11 (a) gezeigte Spektrum resultiert aus 92 % offenem Boden und 8 % Vegetation. Die Reflexionswerte liegen zwischen 8 % - 12 % (blauer Kanal), 12,5 % - 18 % (grüner Kanal), 18,5 % - 20 % (roter Kanal), 20 % - 22 % (rededge Kanal) und 25 % - 28 % (nahes Infrarot). Für die Vegetationsindices ergeben sich Werte von ~1.4 für den RVI und etwa -0.15 für den NDVI. Spektrale Überlappungen mit offenen Ackerflächen und urbanen Flächen sind zu erwarten.

Die Klasse der *Siedlung und Infrastruktur* setzt sich nicht nur aus der tatsächlichen Bebauung zusammen, sondern umfasst ebenso Baum- und Grünlandflächen wie zum Beispiel in städtischen Parkanlagen oder Friedhöfen. Diese Klasse zeichnet sich somit durch eine sehr hohe spektrale Variabilität aus. Zwei für den urbanen Raum typische Spektren – Asphalt und Beton – sind in Abbildung 12 dargestellt. Die Reflexionswerte für Beton liegen zwischen 42 % - 50 % (blauer Kanal), 50 % - 52 % (grüner Kanal), 55 % - 56 % (roter Kanal), 56 % - 57 % (rededge Kanal) und 57 % (nahes Infrarot). Für die Vegetationsindices ergeben sich Werte von 1 für den RVI und etwa 0 für den NDVI. Die Reflexionswerte liegen für Asphalt zwischen 7 % - 8 % (blauer Kanal), 8 % - 10 % (grüner Kanal), 10 % - 11 % (roter Kanal), 11 % - 12 % (rededge Kanal) und 12 % - 13 % (nahes Infrarot). Für die Vegetationsindices ergeben sich Werte von 1.2 für den RVI und 0.1 für den NDVI. Eine spektrale Überlappung ist für die beiden genannten Oberflächentypen für den urbanen Raum vor allem zwischen Asphalt, beschatteten Betonflächen und Wasserflächen zu erwarten.




Abbildung 12: Typische Spektren für offene Asphalt (a) und Beton (b) (Quelle: CLARK ET AL., 2007).

Die spektralen Transformationen sowie die Texturmerkmale können die eben beschriebenen reinen spektralen Merkmale verdrängen, da sie gegebenenfalls die Ausprägungen einzelner Klassen besser wiedergeben. Eine detaillierte Quantifizierung der erwarteten Merkmalsausprägungen bei den Texturmerkmalen ist aufgrund der möglichen, unterschiedlichen Kernelgrößen bei der Berechnung der Merkmale und dem Fehlen einer Texturdatenbank ähnlich der erwähnten Spektraldatenbank des USGS nicht möglich. Allgemein kann jedoch gesagt werden, dass die Textur von der Oberflächenrauigkeit, der Objektausrichtung und den Objektkanten innerhalb des Kernel abhängig ist (RUIZ ET AL., 2004). Mögliche Klassen für eine gesteigerte Erfassbarkeit sind bewirtschaftete Forste, urbane Strukturen

sowie landwirtschaftliche Flächen, welche eine regelmäßige Struktur aufweisen und somit ein von natürlichen Struktur differenzierbares Textursignal erzeugen.

Auch die Transformationen (IC, MNF, PCA) der spektralen Merkmale lassen eine erhöhte Trennbarkeit verschiedener Klassen erwarten. Diese liegt zum einen daran, dass die Informationen der einzelnen spektralen Merkmale durch die Rotation für einige Klassen verstärkt werden können und zum anderen daran, dass der verwendete Klassifikationsalgorithmus sensible auf die Ausrichtung der Merkmale (orthogonal / nicht-orthogonal) reagiert (GERON, 2017).

Ähnlich wie bei den spektralen Merkmalen sind die SAR-Rückstreuwerte der einzelnen Biotoptypen von verschiedenen Faktoren abhängig. Zu diesen Faktoren gehören die Oberflächenrauigkeit, der Einfallswinkel, Geometrie des beobachteten Objektes, die Feuchte und der Wassergehalt des Oberflächenobjekts sowie Polarisierung und räumliche Auflösung. Zum Zeitpunkt des Verfassens dieser Arbeit war keine der spektralen Datenbank des USGS ähnlichen Datenbank für die Rückstreuwerte aus X-Band SAR-Daten bekannt.

Analysen von MCNAIRN & BRISCO, 2004 zeigen, dass die Variation der Rückstreuung für landwirtschaftliche Flächen – in diesem Fall frisch geerntetes Getreide aufgenommen mit einem C-Band SAR - aufgrund des Einfallswinkels ( $20^\circ$  bis hin zu  $50^\circ$ )  $\sim 600\%$  von der niedrigsten Rückstreuung ( $-2$  dB) zur höchsten Rückstreuung ( $-13$  dB) betragen kann (McNairn & Brisco, 2004). Die relative Abweichung der Rückstreuwerte je Einfallswinkel und somit die potenzielle Trennbarkeit der gezeigten Klassen bleibt davon nahezu unberührt.

FURTADO ET AL., 2013 untersuchen für Habitate – Überschwemmungswald, Überschwemmungsgebüsche, Wald, Makrophyten, Offener Boden und Wasser - im Amazonas das Rückstreuverhalten von Radarsat-2 und TerraSAR-X abhängig vom Einfallswinkel, Wellenlänge, räumlicher Auflösung, Polarisierung und Zeitpunkte der Datenerfassung. Die untersuchten Einfallswinkel zeigen bei einigen Klassen einen ähnlichen Einfluss auf die Rückstreuung wie bei MCNAIRN & BRISCO, 2004. Die Variation des Einfallswinkels liegt bei maximal  $16^\circ$  ( $20^\circ$  -  $27^\circ$  und  $36^\circ$  -  $42^\circ$ ) und die höchste Variation bei der Klasse *Wasser*. Hier variiert die Rückstreuung um  $100\%$  ( $-10$  dB zu  $-20$  dB) wahrscheinlich im Zusammenhang mit der Wellenhöhe, Wellenausrichtung und der HH-Bragg-Streuung. Bei anderen Klassen sind die Variationen geringer (FURTADO ET AL., 2013). Aufgrund der unterschiedlichen Länge des Strahlenganges und der damit verbundenen Penetration des Signals in der Vegetationskrone zeigen alle Vegetationsklassen eine Abnahme der Rückstreuung mit Zunahme des Einfallswinkels (FURTADO ET AL., 2013). Den Einfluss der räumlichen Auflösung untersuchen FURTADO ET AL., 2013 unter Verwendung von TerraSAR-X ScanSAR (SCN, 18.5 m), Stripmap (SM, 3.5 m) und Spotlight (SL, 1.5 m) Daten. Grundsätzlich zeigt sich, dass mit steigender räumlicher Auflösung die Rückstreuung sinkt, aber die Klassen inhärente Variation, aufgrund der besseren Abbildung der innerhalb der Klassen vorhandenen Heterogenität, steigt (FURTADO ET AL., 2013). Die untersuchten Polarisierungen (HH, VV und HV) zeigen in den Klassen einen Unterschied in der Rückstreuung, jedoch variiert die relative Abweichung über die Klassen hinweg nur marginal. Die beiden Untersuchungen zeigen bei ausgeschlossenen saisonalen Unterschieden in der Rückstreuung, dass bei den SAR Daten höhere relative Variationen im Vergleich zu den optischen Daten erwartet werden müssen. Konstante Aufnahmeparameter würden die Stabilität der Rückstreuung zwar deutlich erhöhen, jedoch die Trennbarkeit der Klassen untereinander verringern.

Die Kategorie der relationalen und geometrischen Merkmale bilden die sogenannten harten Merkmale und werden anhand fester Definition den Klassen zugeordnet. Dies kann zum Beispiel eine fest definierte Objekthöhe für die Baumvegetation sein, oder die Nachbarschaft zu einer anderen Klasse. Da es sich nicht um erwartete sondern fest definierte Merkmale handelt, werden diese harten Merkmale zusammen mit den verwendeten weichen Merkmalen nicht in diesem Kapitel sondern in Kapitel 6.1 beschrieben.

## 5.2 Klassifikationsansatz

In diesem Kapitel werden die Klassifikationsmethode und ihre Bestandteile dargestellt. Das Kapitel ist unterteilt in die Objektgenerierung (Segmentierung) (Kapitel 5.2.1), der Klassifikationsmethode welche den Top-Down-Ansatz und die Erläuterung der Anwendung des *Random Forest (RF)* Klassifikator umfasst (Kapitel 5.2.2), dem eigentlichen Klassifikationsablauf (Kapitel 5.2.3), der Erzeugung des Häufigkeitsdatensatzes (Kapitel 5.2.4), der Klassenzusammenlegung (Kapitel 5.2.5), der Übertragbarkeit (Kapitel 5.2.6) sowie der Methode zur Genauigkeitsanalyse (Kapitel 5.2.7).

### 5.2.1 Segmentierung

Für die Objekterzeugung wird das *Multiresolution Segmentation (MRS)* Verfahren verwendet (BAATZ & SCHÄPE, 2000, BENZ ET AL., 2004). Objekt-basiert Verfahren haben in der Vergangenheit höhere Genauigkeiten erzeugt als vergleichbare pixel-basierte Ansätze (DURO ET AL., 2012, GOSH & JOSHI, 2014, KASZTA ET AL., 2016, PHINN ET AL., 2012, ROELFSEMA ET AL., 2013, SAUL & PURKIS, 2015). Als Eingangsdaten für die Segmentierung dienen die Rasterdaten (Kapitel 4.2) sowie die daraus erzeugten und in Kapitel 5.1.2 beschriebenen Merkmale. Des Weiteren gehen die AOI-Grenzen als Polygon, Gebäude-, Straßen-, Schienen- und Wasservektoren aus den OSM-Daten mit in die Segmentierung ein.

Um eine für die Daten und das Segmentierungsverfahren optimale Objektgröße zu definieren, wird das *Estimation of Scale Parameters (ESP)* Programm (DRÄGUȚ ET AL., 2010) verwendet. Der mit diesem Programm untersuchte *Scale Parameter* definiert maßgeblich die resultierende Objektgröße. Das für die Einschätzung der optimalen Segmentierungsparameter eingesetzte *Estimation of Scale Parameters (ESP)* Programm (DRÄGUȚ ET AL., 2010) untersucht die lokale Varianz und die Veränderung (*Rate of change (ROC)*) für alle *Scale Parameter* in einem vorgegebenen Bereich. Als Bereich für den *Scale Parameter* wird 1 bis 50 gewählt. Der *Scale Parameter* wird in Schritten von eins variiert. Der Wertebereich der beiden Parameter *Shape* und *Compactness* liegt zwischen 0 und 1. Der Parameter *Shape* wird für die Untersuchung in 0.1 Schritten variiert und der Parameter *Compactness* darf die Werte 0.1, 0.3, 0.5, 0.7, 1 annehmen. Insgesamt werden 50 Läufe durch die möglichen Kombinationen der Parameter durchgeführt. Die signifikanten *Scale Parameter* sind jeweils die mit einem lokalen Maximum im ROC (DRÄGUȚ ET AL., 2010). Die Maxima werden automatisch für jeden Lauf ermittelt und gespeichert.

Abbildung 13 zeigt die resultierenden aufsummierten Häufigkeiten für die lokalen Maxima bei den jeweiligen *Scale Parametern* basierend auf den RapidEye-Daten (a) und den Sentinel-2-Daten (b). Ermittelt man die lokalen Maxima, im Suchradius von fünf Punkten, erhält man als *Scale Parameter* mit den höchsten Änderungsraten die Werte: 20, 24, 28, 33, 44 und 48 für die RapidEye Daten und 22, 26, 30, 36, 43 und 47 für die Sentinel Daten. Das globale Maximum liegt beim Wert 44 (RapidEye) respektive 36 (Sentinel-2). Nach dem *Scale Parameter* von 48 respektive 47 fällt die Häufigkeit des Auftretens auf null. Die sechs genannten *Scale Parameter* werden alle für die Klassifikation herangezogen um eine weitere Ebene der Beurteilung der Genauigkeit zu erhalten. Der Hintergrund ist, dass man durch die verschiedenen *Scale Parameter* unterschiedliche Objekte und somit auch unterschiedliche Klassifikationen erzeugt. Dies tritt vor allem an den Objekt- beziehungsweise Klassenrändern auf. Mithilfe dieser Herangehensweise erhält man Bereiche oder auch Kernbereiche der Klassen mit einer hohen relativen Häufigkeit, welche auf eine gesteigerte Klassifikationssicherheit hindeutet und Randbereiche mit einer geringeren relativen Häufigkeit, da dort verschiedene Klassen, aufgrund der unterschiedlichen Objektbegrenzung auftreten können (Kapitel 5.2.3).

Für die Evaluation der Segmentierungsergebnisse werden Referenzobjekte erzeugt beziehungsweise aus der vorhandenen BNTK-Klassifikation entnommen und diese anhand verschiedener Metriken mit den Objekten der Segmentierung verglichen (RÄSÄNEN ET AL 2013).




Abbildung 13: Aufsummierten Häufigkeiten der lokalen Maxima je *Scale Parameter* für RapidEye (a) und Sentinel-2 (b).

Die verwendeten Metriken sind der *Area fit index (AFI)* (LUCIEER & STEIN, 2002, NEUBERT ET AL., 2008, CLINTON ET AL., 2010, BAR MASSADA ET AL., 2012, RÄSÄNEN ET AL 2013, EINSANK ET AL., 2014), *over merging (OM)* und *under merging (UM)* (YANG ET AL., 1995, CLINTON ET AL., 2010, JOHNSON ET AL., 2012, LIU ET AL., 2012, RÄSÄNEN ET AL 2013, EINSANK ET AL., 2014).

Der AFI gibt Auskunft über die flächenmäßige Ähnlichkeit der Referenzobjekte und der Objekte resultierend aus der Segmentierung. Es wird davon ausgegangen, dass die Objekte sich überlagern und nur die Größen variieren, ein gesonderter Test für die räumliche Überlagerung findet nicht statt. Der AFI ist optimaler Weise null, dies bedeutet eine flächenmäßige Übereinstimmung der Objekte. Ist der AFI negativ ist das Objekt der Segmentierung größer als das Referenzobjekt, ist der AFI positiv, ist das Objekt der Segmentierung kleiner als das Referenzobjekt. Das UM gibt Auskunft ob ein Objekt der Segmentierung kleiner ist als das Referenzobjekt und das OM ob ein Objekt der Segmentierung größer als ein Referenzobjekt ist. Beide Metriken sind ebenfalls im optimalen Fall null. Die Metriken drücken sich wie im Folgenden dargestellt aus.

$$AFI = \frac{(area(x_i) - area(y_i))}{area(x_i)}$$

$$UM = \frac{(area(x_i) - (area(x_i \cap y_i)))}{area(x_i)}$$

$$OM = \frac{(area(y_i) - (area(x_i \cap y_i)))}{area(x_i)}$$

In den Formeln bezeichnet  $area(x_i)$  die Fläche [m<sup>2</sup>] des Referenzobjektes,  $area(y_i)$  die Fläche [m<sup>2</sup>] eines korrespondierenden Objektes aus der Segmentierung. Falls mehr als ein Segment das Referenzobjekt schneidet, werden für jedes Segment die Metriken berechnet, sofern das Segment mit mindestens 50 % der Fläche das Referenzobjekt schneidet. Der letzte in den Formeln verwendete Parameter ist der Überlapp des Referenzobjektes mit einem Segment  $area(x_i \cap y_i)$  [m<sup>2</sup>]. Die ermittelten Parameter für die Segmentierung wie auch die Ergebnisse der Segmentierung werden in Kapitel 6.2 detailliert beschrieben.

### 5.2.2 Klassifikationsmethode

Die Klassifikation wird objekt-basiert durchgeführt, da dies in der Vergangenheit höhere Genauigkeiten ergab als pixel-basierte Ansätze (DURO ET AL., 2012, GOSH & JOSHI, 2014, KASZTA ET AL., 2016, PHINN ET AL., 2012, ROELFSEMA ET AL., 2013, SAUL & PURKIS, 2015). Das Untersuchungsgebiet wird zunächst in allgemeine Klassen unterteilt und anschließend diese Klassen weiter verfeinert. Diesem, von der Klassenhierarchie betrachteten, *Top-Down-Ansatz* (EASTWOOD ET AL., 2006, KURTZ ET AL., 2012, OLEIRE-OLTMANN ET AL., 2011) wird der Vorzug gegenüber einem *Bottom-Up-Ansatz* (EASTWOOD ET AL., 2006, LU ET AL., 2014) gegeben. Ausschlaggebend ist, dass für die Anwendung eines *Bottom-Up-Ansatzes* die räumliche Auflösung der vorhandenen Daten nicht ausreichend ist, um die kleinsten Objekte, welche eine Klasse definieren, zu detektieren.

Basierend auf den Objekten und selektierten Merkmalen wird ein *Random Forest* Klassifikator (BREIMAN, 2001) angewendet. Der *Random Forest* Klassifikator wird ausgewählt, da er in der Vergangenheit erfolgreich bei der Kartierung von Vegetation mittels hoch und sehr hoch aufgelöster Satellitendaten angewendet wurde (BERHANE ET AL., 2018, BARRETT ET AL., 2016, DURO ET AL., 2012, FEILHAUER ET AL., 2014, GOSH & JOSHI, 2014, IMMITZER ET AL., 2012, IMMITZER ET AL., 2016, KASZTA ET AL., 2016, LI ET AL., 2016, LÖW ET AL., 2015, LOWE & KULKARNI, 2015, MA ET AL., 2017). Der *Random Forest* Klassifikator basiert auf dem *Bagging* (*Bootstrap aggregating*) (BREIMAN, 1996). *Bagging* wird verwendet um eine Vielzahl von *Decision Trees* zu generieren und aus diesem die finale Klassenzuweisung vorzunehmen (BREIMAN, 2001, REYNOLDS ET AL., 2016). Die Trainingsdaten werden in homogene Teilmengen unterteilt (MELLOR ET AL., 2013, REYNOLDS ET AL., 2016). Als Trainingsdaten dienen die in Kapitel 4.2.5 beschriebenen Punkte. Die Zuordnung der Daten in die Zielklassen geschieht an Knoten die jeweils zwei Ergebnisklassen zulassen. Alle aus der Merkmalsauswahl resultierenden Merkmale können an den Knoten der *Decision Trees* verwendet werden. Zum Einsatz für die binäre Trennung an einem Knoten kommt das Merkmal welches die Varianz in den resultierenden Teilmengen maximiert (REYNOLDS ET AL., 2016). Für die Evaluation wird eine Teilmenge aus den Trainingsdaten nicht für die *Decision Trees* herangezogen. Diese sogenannten out-of-bag (OOB) Daten ermitteln die Genauigkeit anhand einer Mittelung über alle Ergebnisse der einzelnen *Decision Trees* (BREIMAN, 2001, REYNOLDS ET AL., 2016). Die OOB Daten werden darüber hinaus für die Ermittlung des Einflusses jedes Merkmales auf das Klassifikationsergebnis herangezogen (CUTLER ET AL., 2007, REYNOLDS ET AL., 2016). Zusammengefasst sind die Vorteile des RF Klassifikator nach RODRIGUEZ-GALIANO ET AL., 2012 IN REYNOLD ET AL., 2016:

1. die Anwendbarkeit auf eine große Nummer von Trainingsdaten,
2. Ermittlung des Einflusses jedes Merkmales,
3. sehr performant im Vergleich zu anderen Algorithmen,
4. keine Notwendigkeit im Hinblick auf eine Normalverteilung der Eingangsdaten und
5. robust gegenüber Ausreißern und Rauschen im Datensatz.

Klassifiziert wird jede Klasse einzeln gegen alle anderen Klassen. Als Eingangsdaten dienen die aus der Merkmalsreduktion resultierenden Merkmale für die jeweilige Klasse. Als Parameter für den RF dienen:

1. die maximale Klassifikationsbaumtiefe, d.h. in wie viele Ebenen die Objekte an Knoten geteilt werden dürfen  $[1, \infty]$ ,
2. die minimale Anzahl an Objekten welche an einem Knoten geteilt werden darf  $[1, \infty]$ ,
3. die maximale Anzahl von Clustern in die eine Variable zerlegt werden darf  $[1, \infty]$ ,
4. die Anzahl der aktiven Merkmale an jeden Knoten  $[1, \text{Wurzel aus der Summe an Merkmalen}]$ ,
5. die maximale Anzahl an Klassifikationsbäumen  $[1, \infty]$ ,
6. Klassifikationsgenauigkeit bei der die Klassifikation beendet wird  $[0.01, 1]$  und
7. Abbruchkriterien [maximale Anzahl an Klassifikationsbäumen erreicht, anvisierte Klassifikationsgenauigkeit erreicht, Erfüllung einer der beiden zuvor genannten Kriterien].

Parameter eins wird anhand der Merkmalsreduktion mittels *Random Forest* der Klassen der Hauptgruppe evaluiert und festgesetzt. Getestet werden die Werte 1 bis 20. Die mittlere Genauigkeit (F-Maß) steigt bis zu einer Baumtiefe von fünf an. Anschließend variiert sie nur noch minimal (Tabelle 10 / Abbildung 14). Die Laufzeit des Algorithmus ist von der Baumtiefe nicht signifikant beeinflusst.

Den höchsten Wert erreicht das mittlere F-Maß mit einer Tiefe von 12. Dieser Wert wird für die Klassifikation gesetzt.

Tabelle 10: Evaluation der Klassifikationsgüte unter Verwendung unterschiedlicher Baumtiefen für den RF-Klassifikator.

Baumtiefe	1	2	3	4	5	6	7	8	9	10
F-Maß (Baumveg.)	0.87	0.92	0.94	0.95	0.95	0.95	0.95	0.96	0.96	0.96
F-Maß (Grünland)	0.71	0.82	0.89	0.9	0.89	0.88	0.89	0.91	0.89	0.89
F-Maß (Siedlung)	0.8	0.9	0.94	0.94	0.94	0.94	0.94	0.92	0.92	0.93
F-Maß (Wasser)	0.73	0.77	0.92	0.92	0.94	0.94	0.91	0.9	0.91	0.94
Mittelwert (F-Maß)	0.7775	0.8525	0.9225	0.9275	0.93	0.9275	0.9225	0.9225	0.92	0.93

Baumtiefe	11	12	13	14	15	16	17	18	19	20
F-Maß (Baumveg.)	0.95	0.95	0.96	0.96	0.96	0.95	0.96	0.96	0.96	0.95
F-Maß (Grünland)	0.9	0.9	0.88	0.9	0.88	0.89	0.9	0.9	0.9	0.89
F-Maß (Siedlung)	0.96	0.94	0.92	0.93	0.94	0.92	0.94	0.92	0.92	0.94
F-Maß (Wasser)	0.91	0.94	0.91	0.89	0.89	0.91	0.91	0.92	0.92	0.92
Mittelwert (F-Maß)	0.93	0.9325	0.9175	0.92	0.9175	0.9175	0.9275	0.925	0.925	0.925




Abbildung 14: Visualisierung der Klassifikationsgüte unter Verwendung unterschiedlicher Baumtiefen für den RF-Klassifikator.

Parameter zwei wird bei der Klassifikation nicht limitiert, Parameter drei bleibt auf dem Standardwert von 16, Parameter vier wird exakt auf den Wert der aus der Merkmalsauswahl erhalten Anzahl an Merkmalen für die jeweilige Klasse gesetzt. Parameter fünf wird, wie Parameter eins, anhand der Merkmalsreduktion mittels *Random Forest* der Klassen der Hauptgruppe evaluiert. Betrachtet wird die Veränderung der mittleren Klassifikationsgüte (F-Maß) bei Verdoppelung der verwendeten Bäume (von 10 bis 10240) und die Laufzeit in Minuten. Darüber hinaus wird auch ein Lauf mit nur einem Baum durchgeführt. Als maximal erlaubte Baumanzahl wird 160 gesetzt (Tabelle 11, Abbildung 15). Die resultierenden mittleren Klassifikationsgenauigkeiten unterscheiden sich nur gering (Tabelle 11). Wogegen sich die Laufzeit um das bis zu ~68-fachen unterscheidet. Wobei die Läufe zwischen einem und 160 Bäumen jeweils 12 Minuten, also drei Minuten je Klassen benötigen, braucht der Lauf mit 10240 Bäumen 812 Minuten für alle vier Klassen. Die geringsten Werte in beiden Evaluationskategorien erreicht der Lauf mit nur einem Baum (F-Maß von 0.8875 und 12 Minuten Laufzeit). Die verbleibenden mittleren Werte des F-Maß bewegen sich zwischen 0.9125 (80 Bäume) und 0.9375 (5120 Bäume). Der zweithöchste mittlere Wert des F-Maß (0.9325) wird bei der Baumanzahl 160, 1280 und 5120 erreicht. Um einen Mittelweg zwischen Laufzeit und Genauigkeit zu erreichen wird für die Klassifikation der Parameter fünf anhand der eben beschriebenen Evaluation auf den Wert 160 gesetzt (Abbildung 15).

Tabelle 11: Evaluation der Klassifikationsgüte und Laufzeit unter Verwendung unterschiedlicher Baumanzahl für den RF-Klassifikator.

Anzahl d. Bäume	1	10	20	40	80	160	320	640	1280	2560	5120	10240
F-Maß (Baumveg.)	0.94	0.96	0.95	0.95	0.95	0.95	0.95	0.96	0.96	0.96	0.96	0.96
F-Maß (Grünland)	0.87	0.9	0.87	0.9	0.88	0.89	0.87	0.88	0.89	0.87	0.9	0.87
F-Maß (Siedlung)	0.91	0.95	0.95	0.94	0.93	0.94	0.95	0.93	0.94	0.94	0.94	0.94
F-Maß (Wasser)	0.83	0.88	0.94	0.89	0.89	0.95	0.92	0.93	0.94	0.93	0.95	0.96
Mittelwert (F-Maß)	0.8875	0.9225	0.9275	0.92	0.9125	0.9325	0.9225	0.925	0.9325	0.925	0.9375	0.9325
Laufzeit [min]	12	12	12	12	12	12	32	56	108	204	408	812




Abbildung 15: Visualisierung der Klassifikationsgüte und Laufzeit unter Verwendung unterschiedlicher Baumanzahl für den RF-Klassifikator.

Die Parameter sechs und sieben bleiben auf ihren Standardwerten von 0.01 und *both* gleichbedeutend mit der Verwendung beider Abbruchkriterien. Um eine relative Häufigkeit (Kapitel 5.2.7) für die korrekte Zuordnung jedes Objektes zu der jeweiligen Klasse zu erhalten, wird die Klassifikation mehrfach durchgeführt. Dies resultiert aus den ermittelten, unterschiedlichen Segmentierungsebenen (Kapitel 5.2.1).

### 5.2.3 Klassifikationsablauf

Die Klassifikation basiert auf der in Kapitel 5.2.1 beschriebenen Segmentierung und den daraus resultierenden Objekten. Die Klassifikation findet auf drei Klassifikationsebenen, der Klassen der Hauptgruppe, der Klassen der Untergruppe und den Detailklassen statt und wird für jede Klasse einzeln durchgeführt.

Das grundsätzliche Vorgehen ist gleich und wird im Folgenden beschrieben. Die erzeugte Segmentierungsebene (Ebene 1) wird dupliziert und bildet eine exakte Kopie (Ebene 0) der ersten Segmentierungsebene. Auf der Ebene 1 werden anhand der Referenzpunkte den Objekten Klassen zugeordnet. Mittels dieser Referenzobjekte und den aus der Merkmalsauswahl stammenden Merkmale wird der *Random Forest* Klassifikator trainiert.



Auf der Ebene 0 wird eine Vorklassifikation vorgenommen. Für die erste Klassenebene, die Klassen der Hauptgruppe, (Kapitel 4.5) wird zwischen hoher Vegetation ( $\text{NDVI} > 0.45$ , Objekthöhe  $> 3$  m), niedriger Vegetation ( $\text{NDVI} > 0.45$ , Objekthöhe  $< 3$  m), hoher Nicht-Vegetation ( $\text{NDVI} < 0.45$ , Objekthöhe  $> 3$  m) und niedriger Nicht-Vegetation ( $\text{NDVI} < 0.45$ , Objekthöhe  $< 3$  m) anhand eines multi-temporalen NDVI und der Objekthöhen unterschieden. Ab der zweiten Klassenebene (Klassen der Untergruppe sowie Detailklassen) dient das Ergebnis der vorangegangenen Klassenebene als Vorklassifikation. Auf der Ebene 0 und einer oder mehrerer Vorklassen wird anschließend der trainierte *Random Forest* angewendet. Es findet immer ein Training beziehungsweise eine Klassifikation „eine-gegen-alle“ statt, das heißt es wird immer nur eine Klasse trainiert und zugewiesen, die restlichen Klassen werden in einer Klasse zusammengefasst. Als letzter Schritt wird die Klasse als Vektorfile für die Weiterverarbeitung exportiert (Abbildung 16). Dieser Ablauf gilt für alle Klassen basierend auf weichen Merkmalen (Kapitel 4.5).




Abbildung 16: Klassifikationsablauf für Klassen basierend auf weichen Merkmalen.

Für die Klassifikation der Klassen basierend auf harten Merkmalen werden andere, im Folgenden dargestellte, Klassifikationsabläufe verwendet. Bei den Klassen basierend auf harten Merkmalen werden die Segmente nicht mittels des *Random Forest* zugewiesen, sondern anhand der fest definierten Schwellwerte der Merkmalsausprägungen.

Unterschieden werden die Klassifikationsabläufe nach den Zielklassen. Somit gibt es jeweils einen dedizierten Ablauf für die Wald- und Landschaftselementklassen (Abbildung 17), die Siedlungs- und Infrastrukturklassen (Abbildung 18) und die Gewässerklassen. Die Klassifikation für die genannten Klassen basiert auf der in Kapitel 5.2.1 beschriebenen Segmentierung und den daraus resultierenden Objekten. Für die Wald- und Landschaftselementklassen, die Siedlungs- und Infrastrukturklassen und die Gewässerklassen wird das Segmentierungsergebnis dupliziert und anschließend die Ebene 1 auf die Grenzen der Polygone aus der BNTK gebracht. Dies ist notwendig, um die resultierenden Klassen auf der gleichen Objektebene miteinander vergleichen und validieren zu können.




Abbildung 17: Klassifikationsablauf für die Landschaftselement- und Waldklassen.




Abbildung 18: Klassifikationsablauf für die Siedlungs- und Infrastrukturklassen basierend auf harten Merkmalen.

Bei den Wald- und Landschaftselementklassen wird eine Vorklassifikation auf der Ebene 0 mittels der Ergebnisse der Klassen der Haupt- und Untergruppe in zunächst Baumvegetation und anschließend in Laub- beziehungsweise Nadelbestände durchgeführt. Auf der Ebene 1 werden anhand eines festen Flächenschwellwertes von zwei Hektar potenzielle Wald- beziehungsweise Landschaftselementobjekte extrahiert. Auf Basis des relationalen Merkmals der relativen Fläche von Laub- beziehungsweise Nadelbeständen unter einem potenziellen Waldobjekt (Kapitel 4.5) werden die Walddetaillklassen zugewiesen. Die Landschaftselementklassen werden auf Grundlage der potenziellen Landschaftselementobjekte, der relativen Flächen von Laubbeständen und den in Kapitel 4.5 beschriebenen geometrischen Merkmalen zugewiesen. Alle Klassen werden einzeln und für alle Segmentierungsgrößen exportiert (Abbildung 17).

Bei den Siedlungs- und Infrastrukturklassen (Abbildung 18) wird eine Vorklassifikation auf der Ebene 0 mittels der Ergebnisse der Klassen der Haupt- und Untergruppe in zunächst Siedlung und Infrastruktur und anschließend, mittels der thematischen OSM-Daten, in Gebäude und Nicht-Gebäude durchgeführt. Die Gebäudeklasse wird anhand eines festen Flächenschwellwertes von 1000 m<sup>2</sup> in Wohngebäude und Misch- beziehungsweise Industriegebäude weiter unterteilt. Auf Basis des relativen Anteils von Gebäuden allgemein und Gebäudetypen im Speziellen je Polygon auf Ebene 1 werden die finalen Detailklassen (Kapitel 4.5) zugewiesen. Alle Klassen werden einzeln und für alle Segmentierungsgrößen exportiert.

Bei den Gewässerklassen findet eine Vorklassifikation auf Basis der Klassen der Hauptgruppe statt. Die resultierenden Gewässerobjekte werden zusammengefasst und anhand der Fläche und des Länge-Breite-Verhältnisses den Detailklassen (Kapitel 4.5) zugeordnet und exportiert.

#### 5.2.4 Häufigkeitsdatensatz

Durch die Klassifikation der einzelnen Klassen, basierend auf den unterschiedlichen Segmentierungsebenen, entstehen sechs von den jeweils anderen Klassen unabhängige Klassifikationsergebnisse. Dadurch können Flächen in der finalen Klassifikation nicht klassifiziert bleiben beziehungsweise können durch mehrere Klassen abgedeckt sein. Dies ermöglicht die Erzeugung eines flächigen Datensatzes der relativen Häufigkeit, zum einen je Klassen und zum anderen je Klassifikationsebene.

Zunächst wird klassenweise und pixel-basiert ein Datensatz erzeugt, welcher anzeigt, wie oft jeder Pixel durch die spezifische Klasse klassifiziert wurde. Der Wertebereich reicht von 0 (auf keiner Segmentierungsebene wurde das Pixel in der spezifischen Klasse klassifiziert) bis 6 (in allen Segmentierungsebenen wurde das Pixel in der spezifischen Klasse klassifiziert). Der Datensatz wird als relative Häufigkeit ausgedrückt und auf Zehntel zwischen 0 und 1 gerundet.

Darüber hinaus wird ein Datensatz erzeugt, welcher pixel-basiert anzeigt wie oft ein Pixel je Klassifikationsebene zugewiesen wurde. Der theoretische Wertebereich reicht, am Beispiel der Klassen der Hauptgruppe, von 0 (auf keiner Segmentierungsebene wurde das Pixel klassifiziert) bis 24 (in allen Segmentierungsebenen wurde das Pixel in allen Klassen klassifiziert). Durch die Vorklassifikation anhand von NDVI und Objekthöhe reicht der tatsächliche Wertebereich der ersten Klassifikationsebene von 0 bis 18. Der Datensatz wird als relative Häufigkeit ausgedrückt und auf Zehntel zwischen 0 und 1 gerundet, um eine Vergleichbarkeit über alle Klassifikationsebenen hinweg zu erhalten und unabhängig von der eingehenden Klassenanzahl zu sein. Den Wert 1 im normalisierten Datensatz erhalten nur Pixel, welche ausschließlich sechsmal durch eine Klasse erfasst wurden. Bei weniger oder mehr Erfassungen je Pixel sinkt der Wert auf minimal 0.1 (eine Erfassung durch eine Klasse oder mindestens 12 Erfassungen durch mindestens zwei Klassen). Der Wert 0 bleibt nicht klassifizierten Flächen vorbehalten.

### 5.2.5 Klassenzusammenlegung

Um ein flächiges Klassifikationsergebnis mit allen Klassen zu erhalten, müssen die einzelnen Klassen in ein Ergebnis zusammengefasst werden. Anwendung findet eine regelbasierte *decision level fusion* (DONG ET AL., 2009, RASTIVEIS, 2015, POHL & VAN GENDEREN, 1998, ZENG ET AL., 2006). Die Klassenzusammenlegung geschieht anhand der einzelnen Klassifikationsergebnisse, des Datensatzes der relativen Häufigkeit je Klasse und des Datensatzes der relativen Häufigkeit über alle Klassen.

Die Klassenzusammenlegung folgt den folgenden vier Regeln:

1. eine Klasse wird zugewiesen, wenn sie sechsmal an einem Pixel auftritt und der Datensatzes der relativen Häufigkeit dieser Klassifikationsebene 1 ist,
2. sind zwei oder mehr Klassen an einem Pixel vorhanden, wird die Klasse zugewiesen, die den höchsten Wert im Datensatzes der relativen Häufigkeit pro Klasse besitzt,
3. gibt es zwei oder mehrere Klassen mit den gleichen Werten, wird das Pixel anhand einer im Vorhinein empirisch definierten Priorisierung der Klassen zugewiesen,
4. der analysierte Pixel muss einen im Vorhinein definierten relativen Häufigkeitswert (über alle Klassen) übersteigen.

Regel vier verwendet die Werte der relativen Häufigkeit über alle Klassen einer Ebene. Die verwendeten Schwellwerte sind 0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 und 1.0. Dieses Vorgehen erzeugt elf Klassifikationsergebnisse pro Klassenebene. Jedes Ergebnis bildet ein Klassifikationsergebnis mit allen Klassen der jeweiligen Klassifikationsebene und einen Datensatz der relativen Häufigkeit. Diese Datensätze finden in der Genauigkeitsanalyse Anwendung.

### 5.2.6 Übertragbarkeit

Um die Robustheit zu evaluieren wird die Methode zum einen auf das zweite Untersuchungsgebiet (Groitzsch) mit ähnlicher Datenbasis und zum anderen auf einen anderen Datensatz (Sentinel-1-Daten und Sentinel-2-Daten) für das Untersuchungsgebiet Rostock übertragen. Zu diesem Zweck, wird der gesamte Ablauf inklusive Vorprozessierung, Merkmalsauswahl, Klassifikationsregelwerk und Genauigkeit auf die neuen Datensätze übernommen. Anders als z.B. in ROKITNICKI-WOJCIK ET AL., 2011 wird nicht das Klassifikationsregelwerk inklusive Merkmalen und Schwellwerten übertragen, sondern je Datensatz durch die Merkmalsauswahl und das Training des *Random Forest* neu definiert.

### 5.2.7 Genauigkeitsanalyse

Um die Genauigkeit der resultierenden Klassifikation zu ermitteln werden pro Klasse eine Konfusionsmatrix (STORY & CONGALTON, 1986, FOODY, 2002), das F-Maß (POWERS, 2011), die Gesamtgenauigkeit (FOODY, 2002) und der Kappa-Koeffizient (COHEN, 1960, FOODY, 2002) erzeugt. Die Konfusionsmatrix zeigt für jede Klasse die korrekt sowie falsch (richtig positiv (TP), falsch negativ (FN), falsch positiv (FP), richtig negativ (TN), Gesamtanzahl positiv (P) und Gesamtanzahl negativ (N)) zugeordneten Instanzen. Dies kann in absoluten Werten passieren oder auch auf z.B. Prozent normalisiert werden. Aus der Konfusionsmatrix lassen sich Nutzer-, Produzenten- sowie Gesamtgenauigkeit ableiten. Auch der Kappa-Koeffizient ( $\kappa$ ) kann aus den Werten der Konfusionsmatrix errechnet werden und setzt sich aus dem Anteil der tatsächlich beobachteten Übereinstimmungen ( $p_0$ ) sowie dem Anteil zufälliger Übereinstimmungen ( $pe$ ) zusammen.

$$\kappa = \frac{(p_0 - pe)}{(1 - pe)}$$

Der Kappa-Koeffizient ist ein statistisches Maß für die Interrater-Reliabilität und gibt an um wie viel sich das Klassifizierungsergebnis von einem Zufallsergebnis unterscheidet. Die Werte für den Kappa-

Koeffizienten liegen generell zwischen 0 (keine Übereinstimmung) und 1 (komplette Übereinstimmung).

Das F-Maß ist eine Kombination aus Genauigkeit (precision) und Trefferquote oder auch Vollständigkeit (recall).

$$\text{precision} = TP / (TP + FP)$$

$$\text{recall} = TP / P$$

Das F-Maß wird dabei definiert als:

$$2 * \frac{\text{precision} * \text{recall}}{\text{precision} + \text{recall}}$$

Um die Überlappbereiche der Klassen besser zu verstehen wird zusätzlich eine Häufigkeitskarte (Kapitel 5.2.3) für jede Ebene erzeugt um zu zeigen, an welcher Stelle Klassen sich überlagern. Dieser findet ebenfalls in der Genauigkeitsanalyse Anwendung.

## 5.3 Methodik der Merkmalsauswahl

Die Auswahl der Merkmale für jede Klasse wird nach dem im Folgenden beschriebenen Schema durchgeführt. Alle Klassen werden einzeln betrachtet und dabei alle anderen Klassen so behandelt, als würden die Merkmalsausprägungen eine Klasse wiedergeben. Dies vereinfacht vom methodischen Standpunkt aus die Analyse, da ein Zwei-Klassenproblem simuliert wird. Für die weitere Analyse werden alle Merkmale vorverarbeitet und normalisiert. Die Merkmalsauswahl selbst ist unterteilt in das Merkmalsranking (Kapitel 5.3.3) und die Merkmalsreduktion (Kapitel 5.3.4). Für das Merkmalsranking werden Trennbarkeitsmaße aus der Literatur im Hinblick auf ihre Eignung getestet (Kapitel 5.3.2) und anschließend die optimalen Parameter (Kapitel 5.3.3) definiert. Die Merkmalsreduktion (Kapitel 5.3.4) geschieht abschließend auf Basis des selektierten Klassifikationsalgorithmus.

### 5.3.1 Merkmalsvorverarbeitung und Merkmalsnormalisierung

Als Eingangsdaten für die Merkmalsauswahl dienen die Rasterdaten (Kapitel 4.2) sowie die Referenzdaten für die Klassifikation (Kapitel 4.2.5). Aus den Rasterdaten werden die in Kapitel 5.1.2 beschriebenen Merkmale generiert. Im Detail werden für alle Klassen Objekte (Kapitel 5.2.1) erzeugt, welche auch in der Klassifikation Verwendung finden. Jedes dieser Objekte enthält die in Kapitel 5.1.2 beschriebenen Merkmale sowie die dazugehörige Referenzklasse. Die Merkmale werden als CSV-Datei exportiert und weiterverarbeitet. Die Normalisierung, auch Standardisierung genannt, wird für die Merkmalsauswahl benötigt um optimale Ergebnisse zu erzielen (GERON, 2017). Besitzen die Merkmale stark unterschiedliche statistische Merkmale wie Wertbereich, Mittelwert oder Standardabweichung ist eine vergleichbare Evaluation nicht möglich. Dies kann durch das Eliminieren des Mittelwertes und das Strecken mittels der Varianz passieren. Ein Kritikpunkt ist, dass Ausreißer den Mittelwert und die Varianz beeinflussen können. Um dies zu umgehen wird für die Normalisierung der Median und der Interquartilsabstand zwischen dem ersten (25 %) und dritten (75 %) Quartil verwendet. Das Normalisieren wird für jedes Merkmal separat durchgeführt. Abschließend wird der komplette Merkmalsdatensatz in einen Trainingsdatensatz und einen Testdatensatz unterteilt. Dies geschieht anhand einer stratifizierten Teilung in 80 % Trainingsdaten und 20 % Validations- beziehungsweise Testdaten. Durch die stratifizierte Vorgehensweise wird gewährleistet, dass von jeder Klasse 80 % ihrer Ausprägungen unabhängig von der eigentlichen Punktzahl im Trainingsdatensatz und 20 % im Testdatensatz erscheinen.

### 5.3.2 Auswahl der Trennbarkeitsmaße

Um geeignete Trennbarkeitsmaße auszuwählen, welche die in den Gebieten vorkommenden Biotoptypen und alle erzeugten Merkmalen analysieren, wird ein einfaches drei Klassen – drei Merkmale Beispiel erstellt. Verwendet werden die drei Klassen *Gewässer*, *Laubbaumbestand* und *Grünland*. Als Merkmale werden der blaue RapidEye-Kanal der Szene vom 20. August 2009 (im Folgenden bezeichnet als Blauer Kanal), die VV-Polarisation der TerraSAR-X Stripmap-Aufnahme vom 27. April 2009 (im Folgenden bezeichnet als TSX-VV), sowie dem ersten Kanal der MNF-Transformation vom 20. August 2009 (im Folgenden bezeichnet als MNF). Für jede Klasse wird eine repräsentative Fläche von ~ 14000 Pixel ausgewählt und die Merkmale für diese Fläche erzeugt. Abbildung 19 zeigt die Streudiagramme der Merkmale für die gewählten Klassen. Die Merkmale wurden so gewählt, dass die Merkmale visuell anhand ihrer Trennbarkeit für die untersuchten Klassen sortiert werden können. MNF besitzt die höchste Trennkraft, gefolgt von TSX-VV und Blau mit der geringsten Trennkraft. MNF und TSX-VV besitzen eine sehr ähnliche Aussagekraft im Hinblick auf die Trennbarkeit. Dies wurde bewusst gewählt, damit das Ranking der Merkmale besser zu evaluieren ist. Verwendete man eine Kombination aus zwei Merkmalen ergeben sich die Kombinationen Blau / MNF, Blau / TSX-VV und

MNF / TSX-VV (Abbildung 19). Auch hierbei zeigt sich für die Merkmale MNF und TSX-VV eine höhere Trennbarkeit für die Klassen im Vergleich zum blauen Kanal. Um geeignete Trennbarkeitsmaße zu evaluieren wird ihre Aussagekraft anhand des vorgestellten Problems analysiert. Erwartet werden die Wiedergabe der korrekten Reihenfolge sowie eine möglichst hohe Differenzierbarkeit im Ranking. Tabelle 12 zeigt die getesteten Maße sowie das Ranking, den Wert und den normalisierten Wert für die genannten Klassen und Merkmale.

Tabelle 12: Übersicht über die Evaluation der Trennbarkeitsmaße.

	<i>Euklidische Distanz</i>			<i>Chi-Quadrat Test</i>			<i>gain ratio</i>			<i>symmetrical uncertainty</i>		
	R*	V*	Rel. V.*	R*	V*	Rel. V.*	R*	V*	Rel. V.*	R*	V*	Rel. V.*
Blau	3	0.265	0	3	0.377	0	3	0.177	0	3	0.253	0
MNF	2	0.599	0.905	2	0.786	0.902	1	0.483	1	1	0.638	1
TSX-VV	1	0.634	1	1	0.830	1	2	0.205	0.091	2	0.34	0.225

	<i>Support Vector Machines</i>			<i>Random Forest</i>			<i>ReliefF</i>			<i>significance</i>		
	R*	V*	Rel. V.*	R*	V*	Rel. V.*	R*	V*	Rel. V.*	R*	V*	Rel. V.*
Blau	3	0.388	0	3	0.266	0	3	0.0391	0	3	0.6191	0
MNF	1	0.64	1	2	0.599	0.904	2	0.2031	1	2	0.9254	0.713
TSX-VV	2	0.474	0.341	1	0.634	1	1	0.0667	0.168	1	1.0482	1

\*R = Ranking, V = Wert, Rel.V.= relative Wert

Das erwartete Ranking geben der *gain ratio*, die *symmetrical uncertainty* und die *Support Vector Machines* wieder. Die verbleibenden Maße sind nicht in der Lage die Reihenfolge der Merkmale MNF und TSX-VV korrekt wiederzugeben. Lediglich die geringste Trennbarkeit anhand des blauen Kanals wird von allen Merkmalen richtig erkannt.




Abbildung 19: Merkmalsausprägungen für die Klassen Gewässer (Blau), Laubbaumbestand (Dunkelgrün) und Grünland (Hellgrün) des blauen RapidEye-Kanal (20. August 2009), der VV-Polarisation der TerraSAR-X SM-Aufnahme (27. April 2009) und des ersten Kanals der MNF-Transformation (20. August 2009).



Die relativen Abstände, berechnet aus den minimalen und maximalen Werten (V) für jedes Merkmal, der drei Maße mit dem korrekten Ranking zeigen bei den *Support Vector Machines* die höchste Differenzierung gefolgt von der *symmetrical uncertainty* und zuletzt dem *gain ratio*. Die Merkmale unterscheiden sich nicht signifikant im Ranking und der Differenzierung, jedoch zeigt das *Support Vector Machines* Merkmal eine leicht erhöhte Trennbarkeit. Dies gibt den Ausschlag, um die *Support Vector Machines* für das weitere Vorgehen im Bereich des Merkmalsrankings zu verwenden.

### 5.3.3 Merkmalsranking

In der Phase der eigentlichen Merkmalsauswahl pro Klasse dienen die zuvor generierte normalisierten Merkmale als Eingangsdaten. Für die Analyse jeder Klasse, im Hinblick auf das Merkmalsranking, wird das in Kapitel 5.3.2 als aussagekräftigstes Trennbarkeitsmaß die *Support Vector Machine* (SVM) verwendet. Um die optimalen Ergebnisse zu erhalten werden zunächst die Parameter für die SVM evaluiert. Dies ist zunächst der Kerneltyp (BURGES, 1998, GUYON ET AL., 1993, MERCIER & LENNON, 2003, HUANG ET AL., 2002). Getestet werden:

der lineare Kernel,

$$\langle \mathbf{x}, \mathbf{x}' \rangle$$

der polynominale Kernel,

$$\langle \gamma \langle \mathbf{x}, \mathbf{x}' \rangle + r \rangle^d$$

der *Radial Basis Function* (RBF) Kernel

$$\exp\{-\gamma |\mathbf{x} - \mathbf{x}'|^2\}$$

und der sigmoidale Kernel.

$$\tanh(\gamma \langle \mathbf{x}, \mathbf{x}' \rangle + r)$$

Die mathematischen Ausdrücke sind definiert als:

$\mathbf{x}, \mathbf{x}'$	Merkmalsrepräsentationen,
$r$	Koeffizient 0,
$\gamma$	Gamma,
$d$	polynomialer Grad.

Um den jeweiligen Kerneltyp zu optimieren werden die Parameter  $C$ ,  $r$ ,  $\gamma$  und  $d$  in festen Wertebereichen iteriert um das Maximum in der Zuordnung der Klasse anhand der SVM zu erreichen. Die Wertebereiche werden so gewählt, dass bei keiner Iteration das Maximum für den jeweiligen Kernel erreicht wird (Tabelle 13). Der Parameter  $C$  beeinflusst alle Kernel und bildet einen trade-off zwischen Fehlklassifikationen und der Komplexität der Hyperebene. Die anderen Parameter beeinflussen zwischen einem und drei der genannten Kernel. Gamma ( $\gamma$ ) definiert den Einflussbereich eines jeden Samples. Ein hoher Gamma-Wert führt zu einem geringeren Einflussbereich eines jeden Samples, während ein Gamma-Wert nahe Null einen hohen Einflussbereich eines jeden Samples zulässt. Der polynominale Grad ( $d$ ) definiert die erlaubte polynominale Ordnung des polynomialen Kernel. Der Parameter  $r$  dient der Skalierung der Merkmalspaare um eine asymptotische Konvergenz gegen unendlich zu verhindern. Als Evaluationsgrundlage dienen die Klassen der Hauptgruppe (Kapitel 4.5) und als Gütemaß das *F-Maß* (Kapitel 5.2.7). Die Unterschiede sind nicht stark, allerdings liegt der RBF Kernel minimal vor dem polynomialen, dem sigmoidalen und dem linearen Kernel (Abbildung 20, Tabelle 13) und wird deshalb gewählt. Die finalen Werte für die Parameter bilden sich aus dem Median der Ergebnisse der einzelnen Klassen (Tabelle 13). Mit dem so ermittelten Kernel inklusive der ermittelten Parameter wird das Merkmalsranking für alle Klassen durchgeführt.






Abbildung 20: Kernelperformance für die Klasse Baumvegetation.

Tabelle 13: Ergebnisse und Parameter der Kernel Evaluation der Klassen der Hauptgruppe.

Kernel – B00	F-Maß	C	$\gamma$	r	d	Iterationen	Mögl. Iterationen
Linear	0.9112	1.75	-	-	-	7	150
Polynomial	0.9237	7.25	2.25	0.02	4	3716	100000
Sigmoidal	0.9192	0.25	2.0	0.21	-	10351	25000
Radial basis function	0.9269	36.25	11.25	-	-	6745	7500
Kernel – L00	F-Maß	C	$\gamma$	r	d	Iterationen	Mögl. Iterationen
Linear	0.7708	8.25	-	-	-	33	150
Polynomial	0.8044	12.25	2.25	0.03	4	5796	100000
Sigmoidal	0.7715	0.25	0.25	0.34	-	16501	25000
Radial basis function	0.795	17.75	7.75	-	-	4571	7500
Kernel – S00	F-Maß	C	$\gamma$	r	d	Iterationen	Mögl. Iterationen
Linear	0.7685	0.25	-	-	-	1	150
Polynomial	0.8122	1.75	0.75	0.01	4	428	100000
Sigmoidal	0.8029	0.25	0.5	0.35	-	17051	25000
Radial basis function	0.8431	36.25	12.5	-	-	7495	7500
Kernel – W00	F-Maß	C	$\gamma$	r	d	Iterationen	Mögl. Iterationen
Linear	0.4802	1.0	-	-	-	4	150
Polynomial	0.693	1.25	0.25	0.01	4	20	100000
Sigmoidal	0.2824	0.25	1.0	0.48	-	23651	25000
Radial basis function	0.7619	36.75	12.25	-	-	7347	7500

Finale Parameter (Median) für die Merkmalsevaluation

Kernel	C	$\gamma$
Radial basis function	36.25	11.75

### 5.3.4 Merkmalsreduktion

Mittels des im vorangegangenen Kapitel optimierten *radial basis function* Kernel werden die Merkmale pro Klasse anhand des F-Maß (Kapitel 5.2.7) sortiert. Da das Merkmalsranking nur eine Aussage über das einzelne Merkmal je Klasse zulässt ist es notwendig die sortierten Merkmale dahingehend zu untersuchen, wie sie im Zusammenspiel die Klassifikationsgüte beeinflussen. Dies geschieht mittels der Merkmalsreduktion.

Die Referenzpunkte je Klasse werden für die aus dem Merkmalsranking resultierenden, sortierten und normalisierten Merkmale anhand der in Kapitel 5.2.2 beschriebenen *Random Forest* Klassifikationsmethode evaluiert.

Klassifiziert wird zunächst das Merkmal mit dem höchsten F-Maß aus der *Support Vector Machine* Merkmalsauswahl. Das F-Maß für die Klassifikation nur mit dem ersten Merkmal wird gespeichert. Anschließend werden das erste und das zweite Merkmal für die Klassifikation herangezogen. Wenn das resultierende F-Maß höher liegt als bei der Klassifikation nur des ersten Merkmals wird das zweite Merkmal den für die Klassifikation zu verwendeten Merkmalen hinzugefügt. Falls das F-Maß niedriger ist oder gleichbleibt, wird das hinzugefügte Merkmal verworfen. Dieser Vorgang wird für alle Merkmale wiederholt und nur diejenigen Merkmale gespeichert, welche das resultierende F-Maß erhöhen. Somit werden Redundanzen welche durch das Merkmalsranking mittels *Support Vector Machine* (SVM) nicht erfasst werden konnten eliminiert. Die resultierenden Klassifikationsgenauigkeiten dienen der Evaluation der Merkmale und nicht zur Evaluation der Genauigkeit der flächendeckenden Klassifikation der Untersuchungsgebiete.

Die mit Hilfe dieser Methode ermittelten Merkmale werden in der Klassifikation der Klassen verwendet. Die detaillierten Ergebnisse der Merkmalsauswahl werden in Kapitel 6.1 dargestellt.

## 5.4 Synergie

Generell gibt es verschiedene Arten der Synergie die betrachtet werden können. Dies kann der Einfluss der verschiedenen Datenquellen auf die Segmentierungsergebnisse sein oder der Einfluss der verschiedenen Datenquellen auf das Ergebnis der Merkmalsauswahl beziehungsweise Klassifikation. Darüber hinaus ist es möglich die Merkmalsgruppen im Hinblick auf ihren Beitrag zur Klassifikation zu betrachten.

Eine Evaluation der Synergie im Bereich der Segmentierung wird nicht durchgeführt. Dies ist zum einen damit begründet, dass von einer Hinzunahme der SAR-Daten zur Segmentierung abgesehen wird, da durch die stark abweichende Geometrie schlechtere Segmentierungsergebnisse erwartet werden und durch die Literatur bereits bestätigt sind (PETERS ET AL., 2011). Zum anderen wird ein positiver Effekt auf das Segmentierungsergebnis durch die Hinzunahme der thematischen Information vor allem in Hinblick auf die Ableitung kleiner oder schmaler Objekte, wie z.B. Häuser, Straßen und Wasserläufe, unterstellt.

Um die Synergie im Hinblick auf die Datenquellen zu evaluieren werden die Ergebnisse der Merkmalsauswahl und die finale Klassifikation mittels *Random Forest* basierend auf den verschiedenen Kombinationen der Datenquellen betrachtet.

Als Datenquellen werden definiert:

1. Alle Merkmale, welche auf multispektralen Daten beruhen (Reflexion, Textur, Vegetationsindices, Transformationen) – im Folgenden zusammengefasst unter MS,
2. Alle Merkmale welche auf den SAR-Daten beruhen (Rückstreuung und Textur) – im Folgenden zusammengefasst unter SAR
3. Geometrische Merkmale – im Folgenden zusammengefasst unter GEO
4. Alle Merkmale (MS, SAR, GEO = Alle M.) inklusive Vorklassifikation (Vorklas.) und der Werte in der relativen Häufigkeitskarte von 0 (rH0) und 1 (rH1) (Kapitel 5.2.3)

Untersucht werden sieben Kombinationen:

1. MS
2. SAR
3. MS und SAR
4. MS und GEO
5. SAR und GEO
6. Alle M., Vorklas. und rH0
7. Alle M., Vorklas. und rH1

Für die Untersuchung werden die Klassen der Haupt- und Untergruppe sowie die Detailklassen basierend auf weichen Merkmalen herangezogen und das F-Maß als Gütemaß verwendet. Die Ergebnisse der Analyse sind in Kapitel 6.4 dargestellt.

Des Weiteren wird der Anteil der einzelnen Merkmalsgruppen innerhalb der synergistischen Klassifikation betrachtet, um zu ermitteln, welche Merkmalsgruppen den größten Einfluss auf die Klassifikation besitzen (Kapitel 6.1).

## 6 Ergebnisse

---

*„The ground reference data used in a remote sensing project are unlikely to represent a gold standard as error may be contributed from a variety of sources. The latter include, for example, problems arising from mis-location of testing sites, presence of transitional classes, boundaries, typographical errors, restricted access to sites, uncertainties in class definition and temporal mismatches between image and field data acquisition.“*

Foddy, G. M. (2010): Assessing the accuracy of land cover change with imperfect ground reference data. *Remote Sensing of Environment*, 114, 2271–2285.

---

In diesem Kapitel werden zunächst die Ergebnisse der Merkmalsauswahl für das Entwicklungsgebiet Rostock und die beiden Übertragungsgebiete Rostock und Groitzsch beschrieben. Anschließend werden die Segmentierungsergebnisse und den darauf basierenden Klassifikationsergebnissen ebenfalls unterteilt in das Entwicklungsgebiet Rostock und die beiden Übertragungsgebiete Rostock und Groitzsch betrachtet. Abgeschlossen wird das Kapitel durch die Darstellung der Ergebnisse der Synergieeffekte.

### 6.1 Merkmalsauswahl

Die durchgeführte Merkmalsauswahl ist unterteilt in Merkmalsranking und Merkmalsreduktion. Für die Merkmalsauswahl und Merkmalsreduktion werden alle Punkte der Referenzdaten sowie alle Merkmalsausprägungen für die Punkte verwendet. Die Daten werden wie in Kapitel 5.3.1 beschrieben in Trainingsdaten und Testdaten unterteilt. Alle Merkmale werden je Klasse einzeln evaluiert und die Genauigkeit anhand des F-Maßes ermittelt. Anschließend werden die Merkmale basierend auf ihren Ergebnissen im SVM-Merkmalsranking sortiert. Die sortierten Merkmale werden mittels *Random Forest* im Hinblick auf die untersuchte Klasse evaluiert. Dies geschieht zum einen durch die Analyse der Veränderung der Klassifikationsgenauigkeit bei der kumulativen Klassifikation vom ersten bis zum n-ten Merkmal und zum anderen wird untersucht bei welchen Merkmalen sich die Klassifikationsgenauigkeit bei der kumulativen Klassifikation vom ersten bis zum n-ten Merkmal positiv verändert. Hierbei werden die negativ oder neutral auf die Klassifikationsgenauigkeit wirkenden Merkmale eliminiert und die finalen Merkmale für die Klassifikation selektiert (Kapitel 5.3.4). Die Klassen werden einzeln und ebenenweise betrachtet. Die Ergebnisse werden getrennt anhand des Entwicklungsgebietes Rostock und der beiden Übertragungsgebiete Rostock und Groitzsch beschrieben.

#### 6.1.1 Entwicklungsdatensatz Rostock

Zur ersten Ebene und somit zu den Klassen der Hauptgruppe zählen die Baumvegetation, Gewässer, Grünland sowie Siedlung und Infrastruktur (Kapitel 4.5). Mit diesen Klassen wird wie in Kapitel 5.3 beschrieben zunächst jedes einzelne Merkmal evaluiert. Abbildung 21 zeigt für die Klassen der Hauptgruppe das F-Maß je Merkmal. Die Merkmale sind in keiner der Genauigkeit entsprechenden Reihenfolge, sondern in einer dem Export entsprechenden zufälligen Reihenfolge. Zu erkennen ist, dass unabhängig vom verwendeten Merkmal das F-Maß in einem gewissen Wertbereich schwankt. Für die

Klasse Baumvegetation (a) bewegt sich das F-Maß zum Großteil im Bereich zwischen 0.5 und 0.8 (Abbildung 21 (a)). Einige Merkmale zeigen keine Trennbarkeit ( $F\text{-Maß} = 0$ ) für die untersuchte Klasse. Für die Gewässerpunkte (b) bewegen sich die Werte des F-Maß im Bereich von 0.2 bis 0.7 und somit generell unter den Werten der Baumvegetation (Abbildung 21 (b)). Die Grünlandpunkte zeigen das homogenste Ergebnis mit Werten zwischen 0.4 und 0.6 mit wenigen etwas höheren Werten (Abbildung 21 (c)). Die Siedlung- und Infrastrukturgpunkte (Abbildung 21 (d)) zeigen ein ähnlich heterogenes Ergebnis wie die Gewässerpunkte mit Schwankungen zwischen 0.2 und 0.7.




Abbildung 21: F-Maß (y-Achse) je Merkmal (x-Achse) für die Klassen der Hauptgruppe.

Die Merkmale werden anhand des ermittelten F-Maßes sortiert und kumulativ zur Klassifikation hergezogen. Wie bereits beschrieben dient dieser Schritt zur Merkmalsreduktion. Abbildung 22 zeigt zunächst wie sich das F-Maß verändert wenn man beginnend beim ersten Merkmal kumulativ alle Merkmale klassifiziert. Der Anstieg der Genauigkeit im Falle der Baumvegetation durch die Hinzunahme eines weiteren der bereits anhand des F-Maßes sortierten Merkmale setzt sich bis zum vierten Merkmal fort. Dann bilden sich immer häufiger Plateaus in der die erzielte Genauigkeit stagniert und in einzelnen Fällen sinkt die Genauigkeit bei der Hinzunahme eines weiteren Merkmals wieder (Abbildung 22). Auch bei den anderen Klassen setzt sich dieser Trend bis zum fünften (Grünland), vierten (Siedlung und Infrastruktur) beziehungsweise beim ersten (Gewässer) Merkmal fort. Bei den nachfolgenden Merkmalen bilden sich auch hier Plateaus beziehungsweise sinkt die Genauigkeit bei der Hinzunahme weiterer Merkmale. Die Schwankungen sind bei der Gewässer-Klasse am stärksten ausgeprägt, bei der Baumvegetation am geringsten. Dies macht es notwendig nur die Merkmale zu ermitteln, welche die Genauigkeit tatsächlich erhöhen. Abbildung 23 zeigt die Merkmale für die betrachteten Klassen, welche die Genauigkeit tatsächlich steigern. Bei der Baumvegetation sind dies das Merkmal der Objekthöhe (NDSM) gefolgt von der Mittelwert-Textur des rededge Kanals, dem GRVI und der Mittelwert-Textur des grünen Kanals der RapidEye-Szene vom 20.07.2010. Darüber hinaus erhöht das 23te Merkmal der NDGI der RapidEye-Szene vom 20.07.2010 das F-Maß weiter. Die selektierten Merkmale erscheinen logisch, da es die Objekthöhe erlaubt die Baumvegetation von Grünland und Gewässer zu unterscheiden, lediglich eine Missklassifikation mit Gebäuden in der

Siedlung- und Infrastrukturklasse ist somit möglich. Diese wird mit der Hinzunahme der weiteren Merkmale reduziert. Dies bedeutet für die Baumvegetationsklasse eine Reduktion von 318 Merkmalen auf lediglich fünf Merkmale um die maximale Genauigkeit basierend auf den betrachteten Testflächen zu erreichen (Abbildung 23). Alle Merkmale für diese Klasse werden aus einer Szene verwendet. Dies deutet darauf hin, dass dieser Zeitpunkt im Besonderen dazu geeignet ist, die Baumvegetation von den anderen Klassen zu trennen.




Abbildung 22: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl.

Das F-Maß für die Gewässer-Klasse erhöhen die folgenden Merkmale: das NIR Band der RapidEye-Szene vom 20.08.2009, das NIR Band, die NIR Mittelwert-Textur und das dritte Band der MNF-Transformation der RapidEye-Szene vom 09.07.2010, das zweite Band der MNF-Transformation der RapidEye-Szene vom 20.07.2010, die Kompaktheit, die Varianz-Textur des rededge Bandes der RapidEye-Szene vom 20.07.2010, die Mittelwert-Textur des roten Bandes der RapidEye-Szene vom 09.07.2010 sowie die Objektlänge. Anders als zum Beispiel bei der Klasse Baumvegetation werden bei der Gewässer-Klasse nicht nur Merkmale verwendet, welche im SVM-Ranking sehr weit oben stehen, sondern auch Merkmale im unteren Bereich des Rankings. So werden das erste, fünfte, siebte, elfte, 28te, 52te aber auch das 99te, 167ste und 267ste Merkmal des SVM-Rankings verwendet (Abbildung 23). Ein möglicher Grund kann die Anzahl der Samples dieser Klasse sein. Im Vergleich zu den anderen Klassen

besitzt die Gewässer-Klasse die geringste Anzahl an Samples. Dies kann sich auf das Ranking mittels SVM auswirken und somit auch auf die Merkmalsauswahl mittels *random forest*.

Die Grünland-Klasse benötigt die Merkmale: Objekthöhe, Varianz-Textur des NIR Bandes der RapidEye-Szene vom 09.07.2010, das zweite Band der IC-Transformation der RapidEye-Szene vom 20.08.2009, die Dissimilarity-Textur des NIR Bandes der RapidEye-Szene vom 06.06.2010, die Varianz-Textur des NIR Bandes der RapidEye-Szene vom 20.07.2010, das erste Band der PCA-Transformation der RapidEye-Szene vom 20.00.2009, das blaue Band der RapidEye-Szene vom 09.07.2010, die geometrischen Merkmale Objektvolumen und -dichte, die Second Moment-Textur des NIR Bandes der RapidEye-Szene vom 20.07.2010, die Homogeneity-Textur des grünen Bandes der RapidEye-Szene vom 09.07.2010 und die Dissimilarity-Textur der VV-Polarisation der TerraSAR-X Szene vom 27.04.2009 um das höchste F-Maß zu erreichen (Abbildung 23).

Die Siedlung und Infrastruktur-Klasse benötigt sechs Merkmale um den höchsten Wert des F-Maßes zu erreichen. Die Merkmale sind: das zweite Band der PCA-Transformation der RapidEye-Szene vom 06.06.2010, die Mittelwert-Textur des blauen Bandes der RapidEye-Szene vom 09.07.2010, das rote Band der RapidEye-Szene vom 06.06.2010, die Mittelwert-Textur der RapidEye-Szene vom 20.07.2010, die Varianz-Textur des roten Bandes der RapidEye-Szene vom 09.07.2010 und die Kantenlänge.




Abbildung 23: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern.

Die Merkmalsauswahl im Bereich der Klassen der Untergruppe untersucht, welche Klassen anhand der weichen Merkmale getrennt werden können. Dies sind für Baumvegetation die Klassen der Untergruppe Laubbaumbestände und Nadelbaumbestände. Die Gewässer-Klasse wird nicht weiter anhand von weichen Merkmalen getrennt. Die Grünland-Klasse wird unterteilt in Grünland und Grasland, Landwirtschaftliche Nutzfläche sowie Moor und Sumpf. Die Siedlung und Infrastruktur-Klasse wird unterteilt in versiegelte Flächen und offenem Boden. Abbildung A 3 zeigt das F-Maß für die unsortierten Merkmale. Die meisten Werte für die Punkte der Laubbaumbestände liegen zwischen 0.2 und 0.8 mit einigen Ausreißern mit einem F-Maß von 0 und somit keiner Trennbarkeit, die Nadelbaumbestände Werte besitzen einen Wertebereich von 0.4 bis 0.8.

Die sortierten und kumulativ zur Klassifikation herangezogenen Merkmale zeigen das gleiche Verhalten wie bei den Klassen der Hauptgruppe. Das heißt die Klassifikationsgenauigkeit steigt zunächst an, fällt dann jedoch unter Hinzunahme weiterer Merkmale, teils deutlich, unter das Niveau des ersten Merkmals (Hughes-Effekt (HUGHES, 1968)). Diesen Effekt zeigen alle Klassen der Untergruppe. Am stärksten ausgeprägt ist der Hughes-Effekt bei den Klassen Moor und Sumpf (Abbildung A 5) und Offener Boden (Abbildung A 7) zu beobachten. Dies sind die beiden Klassen mit der geringsten Sampleanzahl. Die Klassen der Untergruppe zeigen höhere Schwankungen und einen stärkeren Hughes-Effekt im Vergleich zu den Klassen der Hauptgruppe.

Für die weitere Unterteilung der Baumvegetation werden für die Laubbaumbestände die Merkmale: fünftes Band der MNF-Transformation der RapidEye-Szene vom 06.06.2010, das zweite Band der IC-Transformation der RapidEye-Szene vom 06.06.2010, das vierte Band der MNF-Transformation der RapidEye-Szene vom 09.07.2010, das erste Band der IC-Transformation der RapidEye-Szene vom 09.07.2010 und das vierte Band der PCA-Transformation der RapidEye-Szene vom 20.08.2009 benötigt. Die Klasse der Nadelbaumbestände verwendet das dritte Band der MNF-Transformation und das zweite Band der IC-Transformation der RapidEye-Szene vom 06.06.2010 als Merkmale für die Klassifikation. Somit werden für die weitere Unterteilung der Baumvegetation nur Merkmale der spektralen Transformation herangezogen. GERON, 2017 vermerkt hierzu, dass *Decision Trees*, welche die Grundlage für den *Random Forest* bilden, sensitiv gegenüber der Ausrichtung beziehungsweise Rotation der Samples sind. So können Trennungen deutlich einfacher orthogonal vorgenommen werden.

Die Merkmale aus der Merkmalsreduktion für Grünland- und Graslandklasse sind das fünfte Band der MNF-Transformation der RapidEye-Szene vom 09.07.2010, die Korrelation-Textur des NIR-Bandes der RapidEye-Szene vom 20.08.2009, die Second Moment-Textur des grünen Bandes der RapidEye-Szene vom 09.07.2010 und die Kontrast-Textur des grünen Bandes der RapidEye-Szene vom 20.07.2010.

Für die Klasse Landwirtschaftliche Nutzflächen werden die Merkmale: Varianz-Textur des NIR-Bandes der RapidEye-Szene vom 20.08.2010, das grüne Band der RapidEye-Szene vom 20.08.2010, das erste Band der MNF-Transformation der RapidEye-Szene vom 20.08.2010, das erste Band der IC-Transformation der RapidEye-Szene vom 06.06.2010 und die Mittelwert-Textur des rededge-Bandes der RapidEye-Szene vom 06.06.2010 verwendet.

Die Klasse Moor und Sumpf benötigt die meisten Merkmale der Klassen der Untergruppe für eine erfolgreiche Trennung. Diese sind die Dissimilarity-Textur des NIR-Bandes der RapidEye-Szene vom 20.07.2010, die Mittelwert-Textur des rededge-Bandes der RapidEye-Szene vom 20.08.2010, das rededge-Band der RapidEye-Szene vom 20.08.2010, die Mittelwert-Textur des rededge-Bandes der RapidEye-Szene vom 20.07.2010, das erste Band der PCA-Transformation der RapidEye-Szene vom 06.06.2010, das grüne Band der RapidEye-Szene vom 20.08.2010, die Objektdichte, das blaue Band der RapidEye-Szene vom 20.07.2010, die Varianz-Textur des blauen Bandes der RapidEye-Szene vom 20.07.2010 und die Dissimilarity-Textur der RapidEye-Szene vom 09.07.2010.



Die Klasse Offener Boden wird nur anhand von einem Merkmal, der Kontrast-Textur des grünen Bandes der RapidEye-Szene vom 06.06.2010, klassifiziert. Dies ist die geringste Anzahl an Merkmalen aller Klassen der Haupt- beziehungsweise Untergruppe. Zurückzuführen ist dies auf die geringe Sampleanzahl und der damit verbundenen, für den Algorithmus, leichten Trennung dieser wenigen Samples von den anderen Klassen. Allerdings gibt der Algorithmus auch gleichzeitig keine sehr hohe Güte (F-Maß von 0.67) für die Trennung an (Abbildung A 8).

Die Klasse versiegelter Boden wird durch drei Merkmale getrennt. Diese sind das zweite Band der IC-Transformation der RapidEye-Szene vom 20.07.2010, die Objektlänge und die Second Moment-Textur des roten Bandes der RapidEye-Szene vom 09.07.2010.

Die Unter- und Detailklassen werden zum überwiegenden Teil anhand von harten Merkmalen definiert. Eine Ausnahme bilden die Detailklassen der Klasse der Untergruppe Grün- und Grasland. Bei diesen Klassen werden weiche Merkmale anhand der Merkmalsauswahl selektiert.

Tabelle 14: Detailklassen der Baumvegetation und verwendete harte Merkmale.

Wald	Fläche > 2 ha / Objekthöhe > 5 m
Laubwald	Anteil Laubbaumbestände > 95 %
Laubwald gemischt	Anteil Laubbaumbestände > 90 % / Anteil Nadelbaumbestände < 10 %
Laubmischwald	Anteil Laubbaumbestände 70 - 90 % / Anteil Nadelbaumbestände 10 - 30 %
Mischwald	Anteil Laubbaumbestände 50 % / Anteil Nadelbaumbestände 50 %
Nadelmischwald	Anteil Nadelbaumbestände 70 - 90 % / Anteil Laubbaumbestände 10 - 30 %
Nadelwald	Anteil Nadelbaumbestände > 95 %

Feldgehölz	Fläche < 2 ha
Hecke	linear (Länge/Breite-Verhältnis) / Objekthöhe zw. 0,5 m und 5 m
Gebüsch	nicht- linear (Länge/Breite-Verhältnis) / Objekthöhe zw. 0,5 m und 5 m
Baumreihe	linear (Länge/Breite-Verhältnis) / Objekthöhe > 5 m / Länge => 100 m
Baumgruppe	nicht-linear (Länge/Breite-Verhältnis) / Fläche zw. 0,01 und 2 ha / Objekthöhe > 5 m
Einzelbaum / Solitär	Fläche < 0,01 ha / Objekthöhe > 5 m

Die Baumvegetation (Hauptgruppe) wird bis zu den Grenzen der BNTK-Objekte zusammengefasst und in Wald (Objekte > 2 ha) und Landschaftselemente unterteilt (Kapitel 5.2.3). Die Waldobjekte werden anhand der in Tabelle 14 gezeigten Merkmale in die Detailklassen unterteilt. Die Klassen der Kategorie der Landschaftselemente definieren sich stark über die Struktur und Geometrie. Diese kann durch die Betrachtung der Beschreibungen der jeweiligen Klassen aus den Kartieranleitungen der Bundesländer abgeleitet werden. Einen Überblick über die abzuleitenden Klassen und Merkmale gibt Tabelle 14.

Wald wird laut LUNG (2010) als „Baumbestände jeden Alters heimischer und nichtheimischer Baumarten mit einer Deckung der Baumschicht von mindestens 30 %“ bezeichnet. Des Weiteren gilt eine Fläche von Baumbeständen mit > 0,2 ha als Wald im Sinne des Landeswaldgesetzes Mecklenburg-Vorpommers (LUNG, 2010). Zur Ableitung von Wald wurde jedoch ein Flächenschwellwert von 2 ha verwendet, da die Feldgehölze, Feldhecken, Baumgruppen sowie Baumreihen und Einzelbäume jeweils Untergruppen des Waldes mit einer Fläche < 2 ha bilden. Feldgehölze sind „kleinflächige, nichtlineare Baum- und Strauchbestände (bis zu einer Fläche von 2 ha) in der freien Landschaft. Sie sind in der Regel an mindestens drei Seiten von Landwirtschaftsflächen (Acker, Grünland, Brache) umgeben (LUNG, 2010).“ Feldhecken sind „lineare, vorwiegend aus Sträuchern aufgebaute Gehölze. Sie können von Bäumen durchsetzt (so genannten Überhältern) oder auch dominiert werden (Baumhecken). Teile der

Feldhecke sind auch die krautigen Säume und am Rande der Hecke abgelagerte Lesesteinhaufen (LUNG, 2010).“ Die Baumreihen werden nach (LUNG, 2010) als „einseitige, mindestens 100 m lange Baumreihen entlang von öffentlichen oder privaten Verkehrsflächen und Feldwegen.“ definiert. Sie bestehen aus in etwa gleichaltrigen und vom Erscheinungsbild her gleichartigen Bäumen. Baumgruppen sind als Baumvegetation mit einer Mindestfläche von 100 m<sup>2</sup> definiert. Als Einzelbäume wurden auf der Definition der Baumgruppen aufbauend die Bereiche mit einer Fläche von < 100 m<sup>2</sup> ausgewählt (LUNG, 2010).

Die Detailklassen der Grün- und Graslandklasse sind das Frisches Grünland beziehungsweise Feuchtgrünland, das Trockengrünland, das Salzgrasland und die Ruderal- und Staudenfluren.

Die Klasse Frisches Grünland beziehungsweise Feuchtgrünland wird durch Entropie-Textur des NIR-Bandes der RapidEye-Szene vom 06.06.2010, dem dritten Band der PCA-Transformation der RapidEye-Szene vom 06.06.2010, dem vierten Band der MNF-Transformation der RapidEye-Szene vom 09.07.2010, der Homogeneity-Textur des rededge Bandes der RapidEye-Szene vom 06.06.2010, dem NDGI der RapidEye-Szene vom 09.07.2010 und dem fünften Band der PCA-Transformation der RapidEye-Szene vom 20.08.2009 von den anderen Grün- und Graslandklassen getrennt.

Das Trockengrünland benötigt drei Merkmale für die Trennung. Dies sind das zweite Band der IC-Transformation der RapidEye-Szene vom 20.07.2010, der GRVI der RapidEye-Szene vom 06.06.2010 und das fünfte Band der IC-Transformation der RapidEye-Szene vom 20.08.2009.

Das Salzgrasland wird anhand der Dissimilarity-Textur der RapidEye-Szene vom 20.08.2009, dem NIR-Band der RapidEye-Szene vom 20.08.2009, dem NIR-Band der RapidEye-Szene vom 09.07.2010, dem dritten Band der IC-Transformation der RapidEye-Szene vom 20.07.2010, dem grünen Band der RapidEye-Szene vom 20.08.2009 und dem SAVI der RapidEye-Szene vom 06.06.2010 getrennt.

Die vierte Detailklasse der Grün- und Graslandklasse, die Ruderal- und Staudenfluren, werden mittels des NIR-Bandes der RapidEye-Szene vom 06.06.2010, der Mittelwert-Textur des rededge Bandes der RapidEye-Szene vom 20.07.2010, der Kontrast-Textur des rededge Bandes der RapidEye-Szene vom 09.07.2010, dem NDGI der RapidEye-Szene vom 20.08.2009 und der Objektbreite getrennt.




Abbildung 24: Verteilung der weichen Merkmale auf die Merkmalskategorien (Entwicklungsgebiet Rostock).

Insgesamt werden 71 weiche Merkmale für die Klassifikation der 16 auf den weichen Merkmalen beruhenden Klassen verwendet. Einige Merkmale finden in verschiedenen Klassen Anwendung, insgesamt werden 94 Merkmale benötigt. Die gesamte Liste der verwendeten Merkmale je Klasse

befindet sich im Anhang (Tabelle A 3). Die Anzahl der Merkmale, welche je Klasse verwendet wird, schwankt zwischen einem Merkmal und 13 Merkmalen. Die Merkmalskategorien (Tabelle 9) werden sehr unterschiedlich repräsentiert. So entfallen 35 % (37 Merkmale) auf die Textur basierend auf den optischen Satellitendaten, 29 % (27 Merkmale) auf die spektralen Transformationen, je 14 % (13 Merkmale) auf die rein spektralen Merkmale und die geometrischen Merkmale, 7 % (7 Merkmale) auf die Vegetationsindices und 1 % (1 Merkmal) auf die Textur basierend auf den SAR-Daten.

### 6.1.2 Übertragbarkeitsdatensatz Groitzsch

Im Übertragungsgebiet Groitzsch werden 14 Klassen anhand der Merkmalsauswahl untersucht. Die zwei im Vergleich zum Entwicklungsgebiet entfallenen Klassen sind im Untersuchungsgebiet nicht oder nicht ausreichend vorhanden. Die Repräsentation der Merkmalskategorien variiert stark. Insgesamt werden 56 Merkmale verwendet, wobei einige Merkmale mehrfach in verschiedenen Klassen Anwendung finden und die Gesamtzahl der verwendeten Merkmale auf 68 ansteigt. Die gesamte Liste der verwendeten Merkmale je Klasse befindet sich im Anhang (Tabelle A 4). Die Anzahl der Merkmale, welche je Klasse verwendet wird, schwankt zwischen einem Merkmal und zehn Merkmalen. Die größte Gruppe bildet die Textur generiert aus optischen Satellitendaten mit 46 % (31 Merkmalen), gefolgt von den spektralen Transformationen sowie den reinen spektralen Merkmalen mit je 18 % (12 Merkmalen, den Vegetationsindices mit 9 % (6 Merkmalen), den geometrischen Merkmalen mit 7 % (5 Merkmalen) und je 1 % (1 Merkmal) basierend auf der SAR-Rückstreuung respektive SAR-Textur.




Abbildung 25: Verteilung der weichen Merkmale auf die Merkmalskategorien (Übertragbarkeitsdatensatz Groitzsch).

### 6.1.3 Übertragbarkeitsdatensatz Rostock

Für den Übertragbarkeitsdatensatz Rostock werden zwei Analysen im Hinblick auf die Merkmalsverteilung durchgeführt. Zum einen werden die Merkmalsgruppen entsprechenden des Entwicklungsdatensatzes Rostock und des Übertragbarkeitsdatensatzes Groitzsch untersucht und zum anderen diese Merkmalsgruppen mit der der multi-temporalen Merkmale ergänzt.

Ohne multi-temporale Merkmale werden 74 weiche Merkmale für die Klassifikation der 16 auf den weichen Merkmalen beruhenden Klassen verwendet. Einige Merkmale finden in verschiedenen Klassen Anwendung, insgesamt werden 114 Merkmale benötigt. Die gesamte Liste der verwendeten Merkmale je Klasse befindet sich im Anhang (Tabelle A 5). Die Anzahl der Merkmale, welche je Klasse verwendet wird, schwankt zwischen einem Merkmal und 15 Merkmalen. Die Merkmalskategorien (Tabelle 9)

werden sehr unterschiedlich repräsentiert. So entfallen 35 % (40 Merkmale) auf die Textur basierend auf den optischen Satellitendaten, 25 % (29 Merkmale) auf die spektralen Transformationen, 16 % (18 Merkmale) auf die rein spektralen Merkmale, 3 % (3 Merkmale) auf die geometrischen Merkmale, 11 % (12 Merkmale) auf die Vegetationsindices, 6 % (7 Merkmal) auf die Textur basierend auf den SAR-Daten und 4 % (5 Merkmale) auf die Rückstreuung der SAR-Daten (Abbildung 26).




Abbildung 26: Verteilung der weichen Merkmale auf die Merkmalkategorien (Übertragbarkeitsdatensatz Rostock).

Unter Hinzunahme der multi-temporalen Merkmale werden 76 weiche Merkmale für die Klassifikation der 16 auf den weichen Merkmalen beruhenden Klassen verwendet. Einige Merkmale finden in verschiedenen Klassen Anwendung, insgesamt werden 115 Merkmale benötigt. Die gesamte Liste der verwendeten Merkmale je Klasse befindet sich im Anhang (Tabelle A 6). Die Anzahl der Merkmale, welche je Klasse verwendet wird, schwankt zwischen zwei und 14 Merkmalen. Bei den Merkmalskategorien (Tabelle 9) entfallen 26 % (29 Merkmale) auf die Textur basierend auf den optischen Satellitendaten, 27 % (31 Merkmale) auf die spektralen Transformationen, 12 % (14 Merkmale) auf die rein spektralen Merkmale, 0 % (gerundet - 1 Merkmale) auf die geometrischen Merkmale, 9 % (10 Merkmale) auf die Vegetationsindices, 4 % (5 Merkmal) auf die Textur basierend auf den SAR-Daten, 5 % (6 Merkmale) auf die Rückstreuung der SAR-Daten und 17 % (19 Merkmale) auf die multi-temporalen Merkmale (Abbildung 27).




Abbildung 27: Verteilung der weichen Merkmale auf die Merkmalkategorien inklusive der multi-temporalen Merkmale (Übertragbarkeitsdatensatz Rostock).

## 6.2 Segmentierung

Um die verschiedenen Segmentierungsebenen basierend auf den RapidEye Daten zu evaluieren werden die in Kapitel 5.2.1 beschriebenen Metriken *area fit index* (AFI), *over merging* (OM) und *under merging* (UM) verwendet. Untersucht werden manuell selektierte Referenzobjekte mit Größen zwischen  $\sim 55 \text{ m}^2$  und  $7900 \text{ m}^2$ . Beispielhaft zeigt Abbildung 32 drei Referenzobjekte und die korrespondierenden Objekte der Segmentierung. Betrachtet man im Hinblick auf AFI (Abbildung 29), OM (Abbildung 30) und UM (Abbildung 31) alle untersuchten Objekte, generieren beim AFI und UM die Segmentierungen mit aufsteigendem *Scale Parameter* die zunehmend besseren Objekte. Die Unterschiede sind signifikant, beim AFI liegen sie bei 0.72, 0.65, 0.59, 0.49, 0.38 sowie 0.34 und beim UM bei 0.73, 0.66, 0.6, 0.53, 0.44, 0.41 für die aufsteigenden *Scale Parameter* (20,24,28,33,44,48). Beim OM und allen Objekten ist der Trend umgekehrt aber nicht so signifikant (0.01, 0.01, 0.01, 0.04, 0.07 und 0.07). Dies deutet darauf hin, dass über alle Objekte hinweg generell zu kleine und somit zu viele Objekte erzeugt werden. Um jedoch ein genaueres Bild zu erhalten werden die Referenzobjekte anhand ihrer Größe in sieben Gruppen ( $< 100 \text{ m}^2$ ,  $100 - 200 \text{ m}^2$ ,  $200 - 400 \text{ m}^2$ ,  $400 - 800 \text{ m}^2$ ,  $800 - 1600 \text{ m}^2$  und  $> 4000 \text{ m}^2$ ) eingeteilt und auch anhand der drei Metriken evaluiert (Abbildung 28).




Abbildung 28: Referenzobjektanzahl je Größenkategorie.

Die kleinste Objektkategorie ( $< 100 \text{ m}^2$ ), jedoch mit den meisten Objekten (43 %), generiert für alle drei Metriken sehr gute Werte. Dies liegt daran, dass die Segmentierung dieser kleinen Objekte, wie z.B. Wohnhäuser oder Tümpel durch die Verwendung der OSM-Daten räumlich limitiert ist und einige dieser Objekte (z.B. Solitäre) von ihrer Repräsentation in den Fernerkundungsdaten (z.B. Reflexion oder Rückstreuung) stark von ihrer Umgebung abgegrenzt sind.

Die Objekte zwischen  $100 \text{ m}^2$  und  $200 \text{ m}^2$  (21 % der Referenzobjekte) zeigen beim AFI für die Scale Parameter 20, 24, 28 und 33 sehr gute Werte und bei den Scale Parametern 44 und 48 deutlich negative Werte und somit zu große Objekte an. Dies bestätigen auch die Werte des OM bei den Objekten zwischen  $100 \text{ m}^2$  und  $200 \text{ m}^2$ . Bei den Werten des UM für die Objekte zwischen  $100 \text{ m}^2$  und  $200 \text{ m}^2$  liegen alle Scale Parameter auf einem niedrigen Niveau, jedoch werden bei den Scale Parameter 20, 24, 28 und 33 etwas mehr zu kleine Objekte erzeugt als bei den Scale Parametern 44 und 48.

Bei den Objekten (13 % aller Objekte) mit einer Größe von  $200 \text{ m}^2$  bis  $400 \text{ m}^2$  generiert laut AFI die Segmentierung basierend auf dem Scale Parameter 33 die besten Objekte, gefolgt von den Objekten der Scale Parameter 44, 48, 28 und 24. Die Objekte basierend auf dem Scale Parameter 20 sind laut AFI die am wenigsten passenden Objekte. Diese Aussage wird durch das OM nicht bestätigt. Hier werden für die Scale Parameter 33, 44 und 48 zu große Objekte erzeugt, die Scale Parameter 20, 24 und 28 bilden in dieser Objektgrößenkategorie sehr gute Werte nahe null. Betrachtet man das UM bilden jedoch die Scale

Parameter 20, 24 und 28 bereits zu kleine Objekte, während die Scale Parameter 33, 44 und 48 passendere Objekte erzeugen.




Abbildung 29: Evaluation area fit index (AFI)

Für die verbleibenden Objekte mit einer Größe über 400 m² (23 % der Objekte) zeigt sich nun generell ein sehr ähnliches Bild. Im AFI und UM generieren immer die größten Scale Parameter die niedrigsten und somit besten Werte. Beim OM ist zu erkennen, dass ab einer Größe der Referenzobjekte über 400 m² quasi keine zu großen Objekte mehr erzeugt werden. Dieser Trend wird nur bei den Objekten mit einer Größe zwischen 800 m² und 1600 m² von den Scale Parameter 33, 44 und 48 minimal durchbrochen. Ein Beispiel dafür ist die Segmentierung der Hecke in Abbildung 32.




Abbildung 30: Evaluation over merging (OM)

Zusammenfassend kann gesagt werden, dass die Segmentierungen basierend auf den Scale Parameter 20, 24 und 28 sich nur für Objekte unter 200 m² gut eignen, diese bilden jedoch über die Hälfte der Referenzobjekte (64 %) und sind somit von entscheidender Bedeutung für die Evaluation der Segmentierung. Die Segmente basierend auf dem Scale Parameter von 33 bilden einen Mittelweg zwischen den kleinen und großen Referenzobjekten und liefern für alle Objektgrößen akzeptable Segmente. Die Segmente basierend auf den Scale Parametern 44 und 48 liefern zwischen 200 m² und

1600 m<sup>2</sup> gute Ergebnisse, dies entspricht etwa 28 % der Referenzobjekte. Für die kleineren Objekte sind diese Scale Parameter nicht geeignet, da sie zu einer Untersegmentierung führen und für die größeren Objekte liefern sie, wie alle anderen Scale Parameter auch, zu kleine Segmente.

LI ET AL., 2016 und MA ET AL., 2016 kommen ebenso zu dem Ergebnis, dass mittlere Segmentgrößen, bei einem *Scale Parameter* zwischen 20 und 60, zu einer gesteigerten Gesamtgenauigkeit speziell bei der Verwendung eines *Random Forest* Klassifikators führen. Segmentierung nahe an der Pixelgröße oder mit einem *Scale Parameter* größer 100 führen dagegen zu einer verminderten Gesamtgenauigkeit (LI ET AL., 2016, MA ET AL., 2016).




Abbildung 31: Evaluation under merging (UM)




Abbildung 32: Beispielhafte Darstellung der Segmentierungsebenen, sowie der jeweils pro Referenzobjekt erzeugten Segmente, anhand dreier Objekte.



### 6.3 Klassifikationsergebnisse und Genauigkeitsanalyse

Dieses Kapitel stellt die Ergebnisse der Klassifikation zum einen visuell und zum anderen anhand der Genauigkeiten dar. Der Entwicklungsdatensatz Rostock basierend auf den RapidEye- und TerraSAR-X-Daten wird in Unterkapitel 6.3.1 dargestellt, gefolgt von den Ergebnissen für den Übertragbarkeitsdatensatz Groitzsch ebenfalls basierend auf den RapidEye- und TerraSAR-X-Daten (Unterkapitel 6.3.2). Die Ergebnisse für den Übertragbarkeitsdatensatz Rostock basierend auf den Sentinel-1- und Sentinel-2-Daten schließen das Kapitel ab (Kapitel 6.3.3).

Die Unterkapitel stellen jeweils die Ergebnisse der Klassen der Hauptgruppe und der Untergruppe sowie die Detailklassen getrennt dar. Durch die Erzeugung der elf Klassifikationsergebnisse je Ebene (Kapitel 5.2.5) und des Datensatzes der relativen Häufigkeit der Klassifikationsebene ergeben sich eine Vielzahl von Kombinationen im Hinblick auf den Genauigkeitsanalyse.

Jedes Klassifikationsergebnis, basierend auf der Klassenzusammenlegung anhand der unterschiedlichen Schwellwerte der relativen Häufigkeit, wird mit allen Validationspunkten analysiert (Schwellwert der relativen Häufigkeit = 0). Zusätzlich werden die Validationspunkte ebenfalls anhand der an diesem Pixel vorliegenden relativen Häufigkeit eingeteilt und Validationen mit den Schwellwerten 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 und 1.0 durchgeführt. Die möglichen Kombinationen dieser Vorgehensweise ergeben 121 Validationsergebnisse. Eine kartographische Darstellung, sowie die Darstellung der detaillierten Genauigkeitsmaße findet nur für:

1. die Ergebnisse basierend auf der Klassenzusammenlegung anhand des relativen Häufigkeitsschwellwertes von 0 und der relativen Häufigkeit an der Stelle des Validationspunktes von 0 sowie
2. die Ergebnisse basierend auf der Klassenzusammenlegung anhand des relativen Häufigkeitsschwellwertes von 1 und der relativen Häufigkeit an der Stelle des Validationspunktes von 1 statt.

Die Darstellung aller Validationsergebnisse je Klassifikationsebene inklusive der oben Genannten findet in Form von Abbildungen und Tabellen statt. Die folgenden Validationen werden ausschließlich auf den klassifizierten Flächen durchgeführt. Die nicht-klassifizierten Flächen werden von der Validation ausgeschlossen, da sie in den Statistiken immer als falsch klassifiziert auftreten würden, sich darüber anhand der nicht vorhandenen Zuordnung jedoch keine Aussage treffen lässt.

#### 6.3.1 Entwicklungsdatensatz Rostock

Das Ergebnis der Klassifikation für die Klassen der Hauptgruppe (Baumvegetation (B00), Grünland (L00), Gewässer (W00) und Siedlung und Infrastruktur (S00)) anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 respektive 1 ist in Abbildung 35 respektive Abbildung 36 dargestellt. Die relative Häufigkeit für die Klassifikation der Hauptgruppe ist in Abbildung 37 dargestellt.

87.44 % des gesamten Untersuchungsgebietes konnten mit dem Schwellwert 0 und 69.95 % des gesamten Untersuchungsgebietes konnten mit dem Schwellwert 1 für die relative Häufigkeit klassifiziert werden (Tabelle 15).

Tabelle 15: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Hauptgruppe.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.858	0.925	87.44
1.0	0.936	0.967	69.95

Die verbleibenden Flächen konnten keiner der vier definierten Klassen zugeordnet werden. Die nicht klassifizierten Bereiche für den Schwellwert 0 liegen zum überwiegenden Teil in den landwirtschaftlich genutzten Flächen und im urbanen Raum. Dies lässt darauf schließen, dass die Definition der Klasse *Grünland* und der Klasse *Siedlung und Infrastruktur* anhand der Trainingspunkte diese Flächen nicht oder nicht genügend abgedeckt hat. Mögliche Lösungen sind: diese Flächen stärker in den Trainingspunkten zu repräsentieren oder die Klassen weiter aufzuteilen, um die Flächen in eigenen Klassen darzustellen. Zusätzlich zu den im vorangegangenen genannten Flächen kommen bei einem Schwellwert von 1 weitere nicht klassifizierte Flächen hinzu. Diese befinden sich in großen Teilen ebenso in den Bereichen der Klasse *Grünland* und der Klasse *Siedlung und Infrastruktur*. Bei diesen Flächen spielt nicht nur eine Rolle, dass sie nicht oder nicht genügend durch die Trainingspunkte abgedeckt sind und somit nicht klassifiziert werden, sondern einige Flächen in mehrere Klassen klassifiziert werden und durch den Schwellwert der relativen Häufigkeit nicht in die finale Klassifikation übernommen werden (Abbildung 37). Die flächenmäßig stärkste Abnahme, sowohl relativ als auch absolut, verzeichnet die Grünlandklasse mit 29.19 %, gefolgt von der Baumvegetation (20.73 %), der Siedlung und Infrastruktur (14.51 %) und dem Gewässer (1.65 %).




Abbildung 33: Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).

Für die Genauigkeitsanalyse konnten 96.1 % (Schwellwert 0) respektive 84.5 % (Schwellwert 1) der Validationspunkte verwendet werden. Die verbleibenden 3.9 % respektive 15.5 % liegen in nicht klassifizierten Bereichen. Abbildung 33 zeigt die Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b). Die Trefferquote (Kapitel 5.2.7) (Abbildung 33 a) variiert zwischen 0.78 und 0.99, die Genauigkeit (Kapitel 5.2.7) zwischen 0.77 und 0.99, das F-Maß (Kapitel 5.2.7) zwischen 0.77 und 0.96 für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (Tabelle 16 a). Größere Fehlklassifikationen (> 0.05) gibt im Bereich der Siedlung und Infrastruktur-Klasse (S00) und dem Grünland (0.15) sowie der Baumvegetation (0.07) und der Gewässer-Klasse (W00) mit dem Grünland (0.13) für den Schwellwert 0 (Abbildung 33 a). Für den Schwellwert 1 gibt es größere Fehlklassifikationen (> 0.05) im Bereich der Siedlungs- und Infrastruktur-Klasse (S00) und dem Grünland (0.07) sowie der Baumvegetation (0.05) (Abbildung 33 b). Die Trefferquote (Abbildung 33 b) variiert zwischen 0.88 und 0.1, die Genauigkeit zwischen 0.86 und 1.0, das F-Maß zwischen 0.87 und 1 für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der

Validationspunkte von 1 (Tabelle 16 b). Die absolute und relative Abnahme je Klasse ist hierbei unterschiedlich (Tabelle 16 a/b). Alle betrachteten Genauigkeitsmaße sind bei einem unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 1 höher als bei einem unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0.

Tabelle 16: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B00	0.99	0.93	0.96	1122
L00	0.81	0.99	0.89	324
S00	0.77	0.78	0.77	148
W00	0.99	0.85	0.91	85
Mittelwert / Summe	0.93	0.93	0.93	1679

(b)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B00	0.99	0.97	0.98	996
L00	0.92	1	0.96	289
S00	0.86	0.88	0.87	126
W00	1	1	1	66
Mittelwert / Summe	0.97	0.97	0.97	1477




Abbildung 34: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Hauptgruppe.

Dies drückt sich auch anhand der Werte des Kappa-Koeffizienten (Zunahme von 0.858 auf 0.936) und der Gesamtgenauigkeit (Zunahme von 0.925 auf 0.967), allerdings auch der abnehmenden, klassifizierten Fläche (Tabelle 15) und abnehmenden Anzahl der Validationspunkte aus (Tabelle 16).

Abbildung 34 zeigt den Verlauf der Gesamtgenauigkeit, des Kappa-Koeffizienten, des klassenweisen F-Maßes und der klassifizierten Fläche für alle Klassen der Hauptgruppe und den Schwellwerten der relative Häufigkeit anhand von Box-Plots. Die relative Häufigkeit auf der x-Achse bezieht sich auf den unteren Schwellwert für die Klassenzusammenlegung und das Hinzufügen der Validationspunkte. Die dargestellten Werte bestätigen den für die im vorangegangenen beschriebene Schwellwerte festgestellten Trend der Zunahme der Genauigkeit und Abnahme der klassifizierten Fläche um maximal 20 % beim Erhöhen des Schwellwertes der relativen Häufigkeit.

Die Variation des F-Maßes bei den verschiedenen Schwellwerten der relativen Häufigkeit ist in Abbildung 34 (d) dargestellt. Die Variation ist bei der Klasse B00 am geringsten und bei der Klasse S00 am stärksten ausgeprägt.




Abbildung 35: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.






Abbildung 36: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.






Abbildung 37: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Hauptgruppe.

Die Ergebnisse der Klassen der Untergruppe (Laubbaumbestand (B11), Nadelbaumbestand (B16), Grün- und Grasland (L10), Landwirtschaftliche Nutzfläche (L20), Moor und Sumpf (W40), Offener Boden (R00) und Versiegelte Flächen (S10)) werden im Folgenden dargestellt. Die Gewässerbereiche (W00) werden aus der Hauptgruppe unverändert in die Untergruppe übernommen und deshalb nicht gesondert auf dieser Klassifikationsebene validiert.

88.15 % der von den Klassen der Hauptgruppe maximal klassifizierten Fläche wird von Klassen der Untergruppe mit einem Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 abgedeckt (Tabelle 17). Bei einem Schwellwert von 1 sind es 44.7 % (Tabelle 17). Der Kappa-Koeffizient steigt von 0.817 auf 0.941 und die Gesamtgenauigkeit von 0.856 auf 0.956 (Tabelle 17). Die Klassifikationsergebnisse für den Schwellwert 0 sind in Abbildung 38, für den Schwellwert 1 in Abbildung 39 und die Karte der relativen Häufigkeit für die Klassen der Untergruppe in Abbildung 40 dargestellt.

Tabelle 17: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Untergruppe.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.817	0.856	88.15
1.0	0.941	0.956	44.70

Die Werte für die Genauigkeit, über alle Klassen hinweg, schwanken zwischen 0.32 und 1.0, für die Trefferquote (Abbildung 41 a) zwischen 0.41 und 1 und für das F-Maß zwischen 0.36 und 0.9 für den Schwellwert von 0 (Tabelle 18 a). Für den Schwellwert von 1 schwanken die Werte, über alle Klassen hinweg, für die Genauigkeit zwischen 0.30 und 1.0, für die Trefferquote (Abbildung 41 b) zwischen 0.91 und 1 und für das F-Maß zwischen 0.46 und 1.0 (Tabelle 18 b).

Tabelle 18: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.84	0.96	0.90	196
B16	0.94	0.85	0.89	217
L10	0.88	0.86	0.87	247
L20	0.74	0.86	0.80	43
W40	0.32	0.41	0.36	27
R00	0.40	1.00	0.57	10
S10	1.00	0.79	0.88	129
Mittelwert / Summe	0.88	0.86	0.86	869
(b)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.94	0.97	0.96	118
B16	0.98	0.96	0.97	165
L10	0.99	0.91	0.95	95
L20	0.93	1.00	0.96	27
W40	0.30	1.00	0.46	3
R00	1.00	1.00	1.00	1
S10	1.00	0.98	0.99	46
Mittelwert / Summe	0.97	0.96	0.96	455






Abbildung 38: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.




Abbildung 39: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.






Abbildung 40: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Untergruppe.




Abbildung 41: Konfusionsmatrizen für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).

Die Anzahl der Validationspunkte sinkt deutlich durch die Steigerung des unteren Schwellwertes der relativen Häufigkeit. Bei einem Schwellwert von 1 werden nur noch 52.3 % der Validationspunkte verwendet die noch bei einem Schwellwert von 0 Anwendung finden. Die Klasse Moor und Sumpf verwendet nur noch drei von vorher 27 Validationspunkten, die Klasse Offene Flächen nur noch einen von vorher 10 (Tabelle 18). Die Aussagekraft der Werte dieser beiden Klassen ist aufgrund der wenigen Validationspunkte stark eingeschränkt. Die größten Fehlklassifikationen ( $> 0.05$ ) bei einem Schwellwert von 0 treten zwischen der Nadelwaldklasse (B16) und der Laubwaldklasse (0.14), der Grünlandklasse (L10) mit den Landwirtschaftlichen Nutzflächen (0.05) und der Moor und Sumpf-Klasse (0.09), der Klasse der Landwirtschaftlichen Nutzflächen (L20) mit dem Grünland (0.09) und dem Offenen Boden (0.05), der Moor und Sumpf-Klasse (W40) mit dem Grünland (0.59) sowie der Klasse der versiegelten Flächen (S10) mit dem Offenen Boden (0.09) und dem Grünland (0.05) auf (Abbildung 41 a). Bei einem Schwellwert von 1 gibt es nur noch größere Fehlklassifikationen ( $> 0.05$ ) zwischen der Grünlandklasse (L10) und der Moor und Sumpf-Klasse (0.07) (Abbildung 41 b). Auffällig ist die starke Fehlklassifikation im Bereich der Moor- und Sumpf-Klasse bei dem Schwellwert 0. Diese starke Abweichung ist auch bei weiteren Schwellwerten der relativen Häufigkeit als Ausreißer im F-Maß sichtbar (Abbildung 42 c). Abbildung 42 zeigt den Verlauf der Gesamtgenauigkeit, des Kappa-Koeffizienten, des klassenweisen F-Maßes und der klassifizierten Fläche für alle Klassen der Untergruppe in Abhängigkeit des Schwellwertes der relativen Häufigkeit anhand von Box-Plots. Die relative Häufigkeit auf der x-Achse bezieht sich auf den unteren Schwellwert für die Klassenzusammenlegung und das Hinzufügen der Validationspunkte. Die Variation des F-Maßes je Klasse (Abbildung 42 d) ist bei der Klasse Offener Boden (R00) am stärksten (0.43), deutlich geringere Variationen (0.16 respektive 0.11) treten bei den Klasse Moor und Sumpf (W40) respektive der Klasse Versiegelte Flächen (S10) auf. Die verbleibenden Klassen weisen relativ geringe F-Maßvariationen ( $< 0.1$ ) auf. Bei den Untergruppen ist ein ähnlicher Trend, die Zunahme der Genauigkeit bei Erhöhung des unteren relativen Schwellwertes und eine gleichzeitige Abnahme der klassifizierten Fläche, wie bei den Klassen der Hauptgruppe zu beobachten. Die Abnahme der klassifizierten Fläche um maximal 49.3 % ist bei den Klassen der Untergruppe deutlich stärker ausgeprägt als bei den Klassen der Hauptgruppe. Dies lässt darauf schließen, dass es bei den Klassen der Untergruppe mehr Überlagerungen der einzelnen Klassen, im Vergleich zu den Klassen der Hauptgruppe, gibt. Abbildung 40 bestätigt diesen Schluss, da die Bereiche mit einer relativen Häufigkeit kleiner 1 bei den Klassen der Untergruppe im Vergleich zu den Bereichen bei den Klassen der Hauptgruppe (Abbildung 37) deutlich zunehmen.




Abbildung 42: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Untergruppe.

Als Detailklassen werden die Klassen Laubwald (B11), Laubwald (gemischt) (B12), Laubmischwald (B13), Mischwald (B14), Nadelmischwald (B15), Nadelwald (B16), Feldgehölz / Baumgruppe (B21), Baumreihe (B23), Solitär (B25), Hecke (B26), Gebüsch (B27), Feuchtgrünland (L11), Trockengrünland (L14), Salzgrasland (L15), Ruderal- und Staudenfluren (W40), Wohn- und Mischgebiet (S10), Gewerbegebiet (S30), Verkehrsflächen (S50), Ausdauerndes Kleingewässer (W14), Fluss (W21) und See (W31) klassifiziert. Die Klasse Landwirtschaftliche Nutzfläche wird aus den Untergruppe unverändert übernommen und deshalb nicht bei den Detailklassen validiert. Im Bereich der Detailklassen werden 85.48 % der maximal bei den Klassen der Untergruppe klassifizierten Flächen bei einem unteren Schwellwert der relativen Häufigkeit von 0 erfasst. Bei einem Schwellwert der relativen Häufigkeit von 1 wird eine um 27.5 % kleinere Fläche (61.95 %) erfasst (Tabelle 19).

Tabelle 19: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Detailklassen.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.721	0.739	85.48
1.0	0.751	0.77	61.95

Die Gesamtgenauigkeit steigt leicht von 0.739 auf 0.77 und der Kappa-Koeffizient von 0.721 auf 0.751 bei einer Veränderung des Schwellwertes der relativen Häufigkeit von 0 auf 1 (Tabelle 19). Die geringeren Veränderungen im Bereich der Genauigkeiten (Abbildung 43 a / b) ist auf die Klassen basierend auf den harten Merkmalen zurückzuführen, da diese nicht so stark von den relativen Häufigkeiten beeinflusst werden wie die Klassen basierend auf den weichen Merkmalen. Dies gilt vor allem für die Waldklassen und die Siedlungsklassen, da diese zwar basierend auf den Ergebnissen der



Hauptgruppe klassifiziert werden, die finalen Objekte jedoch auf den städtischen Blockobjekten und den Waldbestandsgrenzen der Biotoptypenkartierung beruhen. Dies drückt sich auch anhand der nahezu gleichbleibenden F-Maßverteilung über alle Klassen aus (Abbildung 43 c / Tabelle 20) sowie den nahezu unveränderten Werten des F-Maßes und der Anzahl der Validationspunkte einiger Wald- und Siedlungsklassen (B11, B12, B13, B14, B15, B16, S30 und S50 (Abbildung 43 d / Tabelle 20)). Die Klassen basierend auf den harten Merkmalen bilden mit 18 von 21 Klassen den überwiegenden Teil der Detailklassen.




Abbildung 43: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Detailklassen.

Die Anzahl der Validationspunkte sinkt deutlich durch die Steigerung des unteren Schwellwertes der relativen Häufigkeit. Bei einem Schwellwert von 1 werden nur noch 76,59 % der Validationspunkte verwendet, die noch bei einem Schwellwert von 0 Anwendung finden. Die Klasse B26, L14 und W40

sinken auf sehr niedrige Werte (<10) (Tabelle 20). Die Aussagekraft der Ergebnisse dieser Klassen ist aufgrund der wenigen Validationspunkte stark eingeschränkt.

Tabelle 20: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Detailklassen für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)

Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.72	0.91	0.80	127
B12	0.96	0.54	0.69	48
B13	0.67	0.74	0.70	53
B14	0.79	0.82	0.81	76
B15	0.68	0.64	0.66	95
B16	0.73	0.66	0.69	105
B21	0.60	0.72	0.66	86
B23	0.82	0.74	0.78	86
B25	0.62	0.93	0.74	14
B26	0.67	0.59	0.62	17
B27	0.82	0.45	0.58	88
L11	0.73	0.78	0.75	68
L14	0.81	0.79	0.80	43
L15	0.54	1.00	0.70	26
S10	0.69	0.64	0.67	64
S30	0.69	0.82	0.75	33
S50	0.88	1.00	0.94	45
W14	1.00	0.93	0.96	14
W21	0.92	0.73	0.81	33
W31	0.96	0.96	0.96	27
W40	0.78	0.67	0.72	27
Mittelwert / Summe	0.75	0.74	0.74	1175

(b)

Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.72	0.91	0.80	127
B12	0.96	0.54	0.69	48
B13	0.67	0.74	0.70	53
B14	0.81	0.82	0.81	76
B15	0.69	0.64	0.67	95
B16	0.73	0.67	0.70	103
B21	0.60	0.82	0.69	40
B23	0.89	0.75	0.81	52
B25	0.69	0.90	0.78	10
B26	0.00	0.00	0.00	4
B27	1.00	0.40	0.57	45
L11	0.90	0.96	0.93	27
L14	0.75	1.00	0.86	6
L15	0.87	1.00	0.93	13
S10	0.70	0.74	0.72	53
S30	0.72	0.84	0.78	31
S50	0.88	1.00	0.94	45
W14	1.00	0.92	0.96	13
W21	0.92	0.89	0.91	27
W31	0.96	0.96	0.96	27
W40	1.00	1.00	1.00	5
Mittelwert / Summe	0.78	0.77	0.76	900




Abbildung 44: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.






Abbildung 45: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.






Abbildung 46: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Detailklassen.

### 6.3.2 Übertragbarkeitsdatensatz Groitzsch

Das Ergebnis der Klassifikation für die Klassen der Hauptgruppe (Baumvegetation (B00), Grünland (L00), Gewässer (W00) und Siedlung und Infrastruktur (S00)) anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 respektive 1 für den Übertragbarkeitsdatensatz Groitzsch ist in Abbildung 49 respektive Abbildung 50 dargestellt.

Tabelle 21: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Hauptgruppe.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.899	0.936	88.8
1.0	0.971	0.981	66.28

Bei einem unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 werden 88.8 % bei einem Schwellwert von 1 werden 66.28 % des gesamten Untersuchungsgebietes klassifiziert (Tabelle 21). Die korrespondierenden Werte für den Kappa-Koeffizienten steigen von 0.899 auf 0.936, die der Gesamtgenauigkeit steigen von 0.936 auf 0.981 (Tabelle 21, Abbildung 48). Die meisten nicht klassifizierten Flächen bei einem Schwellwert 0 befinden sich im Bereich der Grünlandklasse und zu einem geringeren Teil im Bereich der Infrastruktur und Siedlungsklasse. Die stärksten relativen Flächenänderungen zwischen den Schwellwerten 0 und 1 treten bei der Gewässerklasse (Abnahme von 48.21 %) gefolgt von der Baumvegetation (Abnahme von 46.2 %), der Siedlung und Infrastruktur (Abnahme von 31.59 %) und der Grünlandklasse (Abnahme von 20.77 %) auf. Betrachtet man die absoluten Änderungen, so zeigt sich die größte Abnahme bei der Grünlandklasse gefolgt von der Siedlung und Infrastruktur, der Baumvegetation und dem Gewässer. Dies visualisiert die Verteilung der relativen Häufigkeit in Abbildung 51 sowie die Klassifikationsergebnisse in Abbildung 49 und Abbildung 50.




Abbildung 47: Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).

Die Betrachtung der Konfusionsmatrizen für die Schwellwerte 0 und 1 (Abbildung 47) zeigt, dass lediglich bei einem Schwellwert von 0 größere Fehlklassifikationen ( $> 0.05$ ) im Bereich der Baumvegetation und der Grünlandklasse (0.11) auftreten. Die Trefferquote steigt bei drei der vier

Klassen an und bleibt bei der vierten Klasse (Gewässer) gleich auf dem maximalen Wert von 1. Die Genauigkeit, Trefferquote (Tabelle 22), F-Maß (Tabelle 22, Abbildung 48), Gesamtgenauigkeit und der Kappa-Koeffizient (Abbildung 48)) steigen mit Steigerung des unteren Schwellwertes der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte an. Dagegen nehmen die klassifizierte Fläche (Abbildung 48) und die zur Verfügung stehenden Validationspunkte mit steigendem unteren Schwellwert der relativen Häufigkeit ab (Tabelle 22).

Tabelle 22: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B00	0.95	0.88	0.92	213
L00	0.92	0.95	0.94	350
S00	0.95	0.96	0.95	150
W00	1.00	1.00	1.00	17
Mittelwert / Summe	0.94	0.94	0.94	730

(b)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B00	0.98	0.98	0.98	151
L00	0.98	0.98	0.98	276
S00	0.98	0.99	0.98	140
W00	1.00	1.00	1.00	14
Mittelwert / Summe	0.98	0.98	0.98	581




Abbildung 48: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Hauptgruppe.






Abbildung 49: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.




Abbildung 50: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.




Abbildung 51: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Hauptgruppe.



Die Ergebnisse der Klassen der Untergruppe (Laubbaumbestand (B11), Nadelbaumbestand (B16), Grün- und Grasland (L10), Landwirtschaftliche Nutzfläche (L20), Moor und Sumpf (W40), Offener Boden (R00) und Versiegelte Flächen (S10)) sind anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 respektive 1 für den Übertragbarkeitsdatensatz Groitzsch in Abbildung 54 respektive Abbildung 55 dargestellt. Die Gewässerbereiche werden, wie auch schon im Entwicklungsgebiet, unverändert von der Hauptgruppe in die Untergruppe übertragen, aber nicht separat validiert. Bei einem unteren Schwellwert von 0 werden 79.87 %, bei einem unteren Schwellwert von 1 werden 41.24 % der maximal durch die Klassen der Hauptgruppe erfassten Flächen klassifiziert (Tabelle 23). Die Gesamtgenauigkeit steigt von 0.891 auf 0.991 und der Kappa-Koeffizient von 0.859 auf 0.987 (Tabelle 23).

Tabelle 23: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Untergruppe.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.859	0.891	79.87
1.0	0.987	0.991	41.24

Die größten relativen Änderungen zwischen den klassifizierten Flächen bei den Schwellwerten von 0 und 1 gibt es bei dem Nadelbaumbestand (92.65 % Abnahme), gefolgt vom Offener Boden (89.73 % Abnahme), der Moor- und Sumpf-Klasse (88.73 % Abnahme), dem Laubbaumbestand (76.35 % Abnahmen), der Versiegelten Fläche (65.66 % Abnahme), des Grün- und Graslandes (52.06 % Abnahme) und der Landwirtschaftlichen Nutzfläche (27.14 % Abnahme). Die flächenhafte Abnahme ist deutlich von Abbildung 54 zu Abbildung 55 und die dafür verantwortlichen Werte der relativen Häufigkeit in Abbildung 56 zu sehen.




Abbildung 52: Konfusionsmatrizen für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).

Die Betrachtung der Konfusionsmatrizen für die Schwellwerte 0 und 1 (Abbildung 52) zeigt, dass es bei einem Schwellwert von 0 zu größeren Fehlklassifikationen ( $> 0.05$ ) zwischen Nadelbaumbestandes (0.05) und der Moor- und Sumpf-Klasse (0.05), der Landwirtschaftlichen Nutzfläche und dem Offenen Boden, der Moor und Sumpf-Klasse und dem Grün- und Grasland (0.41), dem Offenen Boden und dem Grün- und Grasland (0.21) und der Landwirtschaftlichen Nutzfläche (0.07) sowie der Versiegelten Fläche und dem Offenen Boden (0.18) kommt. Bei einem Schwellwert von 1 kommt es zu größeren Fehlklassifikationen ( $> 0.05$ ) zwischen dem Offenen Boden und der Landwirtschaftlichen Nutzfläche



(0.25). Die Trefferquote steigt bei allen Klassen an beziehungsweise bleibt beim Laubbaumbestand gleich auf dem maximalen Wert von 1 (Tabelle 24).

Tabelle 24: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)

Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.98	1.00	0.99	41
B16	1.00	0.95	0.97	20
L10	0.90	0.97	0.93	162
L20	0.98	0.91	0.94	121
W40	0.80	0.55	0.65	29
R00	0.26	0.71	0.38	14
S10	0.98	0.82	0.90	125
Mittelwert / Summe	0.93	0.89	0.90	512

(b)

Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	1.00	1.00	1.00	28
B16	1.00	1.00	1.00	18
L10	1.00	0.99	1.00	112
L20	0.98	0.99	0.98	95
W40	1.00	1.00	1.00	4
R00	0.75	0.75	0.75	4
S10	1.00	1.00	1.00	60
Mittelwert / Summe	0.99	0.99	0.99	321




Abbildung 53: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Untergruppe.




Abbildung 54: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.




Abbildung 55: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.






Abbildung 56: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Untergruppe.

Wie bei den Klassen der Hauptgruppe steigen die Genauigkeit, die Trefferquote (Tabelle 24), das F-Maß (Tabelle 24, Abbildung 53), die Gesamtgenauigkeit und der Kappa-Koeffizient (Abbildung 53) der Klassen der Untergruppe mit zunehmenden unteren Schwellwert der relativen Häufigkeit an. Gleichzeitig nimmt die Anzahl der Validationspunkte (Tabelle 24) und die klassifizierte Fläche (Abbildung 53) ab. Die Anzahl der Validationspunkte für die Klassen Offener Boden und Moor und Sumpf sinken bei einem Schwellwert von 1 mit nur noch vier Punkten auf einen niedrigen Stand und besitzen somit nur noch bedingt eine Aussagekraft. Dies wird auch sichtbar durch die starke Schwankung innerhalb des F-Maß (0.65 und 1 (W40) sowie 0.38 und 0.75 (R00)) für die beiden Klassen über alle Schwellwerte der relativen Häufigkeit (Abbildung 53 (d)) hinweg.

Als Detailklassen werden die Klassen Laubwald (B11), Laubmischwald (B13), Nadelwald (B16), Feldgehölz / Baumgruppe (B21), Baumreihe (B23), Solitär (B25), Hecke (B26), Gebüsch (B27), Feuchtgrünland (L11), Trockengrünland (L14), Ruderal- und Staudenfluren (W40), Wohn- und Mischgebiet (S10), Gewerbegebiet (S30), Verkehrsflächen (S50), Ausdauerendes Kleingewässer (W14), Fluss (W21) und See (W31) klassifiziert. Die Klasse Landwirtschaftliche Nutzfläche wird aus den Untergruppe unverändert übernommen und deshalb nicht bei den Detailklassen validiert. Die Klassifikation für die Ergebnisse basierend auf einem unteren Schwellwertes der relativen Häufigkeit von 0 beziehungsweise 1 sowie die relative Häufigkeit sind in Abbildung 58, Abbildung 59 respektive Abbildung 60 dargestellt.

Im Bereich der Detailklassen werden 80.08 % der maximal bei den Klassen der Untergruppe klassifizierten Flächen bei einem unteren Schwellwert der relativen Häufigkeit von 0 erfasst. Bei einem Schwellwert der relativen Häufigkeit von 1 werden 53.48 % klassifiziert (Tabelle 25).

Tabelle 25: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Detailklassen.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.739	0.773	80.08
1.0	0.833	0.861	53.48

Die Gesamtgenauigkeit steigt von 0.739 auf 0.833 und der Kappa-Koeffizient von 0.773 auf 0.861 bei einer Veränderung des Schwellwertes der relativen Häufigkeit von 0 auf 1 (Tabelle 25). Die geringeren Veränderungen im Bereich der Genauigkeiten (Abbildung 57 a / b) ist auf die Klassen basierend auf den harten Merkmalen zurückzuführen, da diese nicht so stark von den relativen Häufigkeiten beeinflusst werden wie die Klassen basierend auf den weichen Merkmalen. Dies gilt vor allem für die Waldklassen und die Siedlungsklassen, da diese zwar basierend auf den Ergebnissen der Hauptgruppe klassifiziert werden, die finalen Objekte jedoch auf den städtischen Blockobjekten und den Waldbestandsgrenzen der Biotoptypenkartierung beruhen. Dies drückt sich auch anhand der nahezu gleichbleibenden F-Maßverteilung über alle Klassen aus (Abbildung 57 c / Tabelle 26Tabelle 20) sowie den nahezu unveränderten Werten des F-Maßes und der Anzahl der Validationspunkte einiger Wald- und Siedlungsklassen (B11, B13). Die Klassen basierend auf den harten Merkmalen bilden mit 14 von 17 Klassen den überwiegenden Teil der Detailklassen.

Auch bei den Detailklassen nimmt die Genauigkeit mit steigendem unteren Schwellwert der relativen Häufigkeit zu, während die klassifizierte Fläche und die Anzahl der Validationspunkte je Klasse abnimmt. Die Anzahl der Validationspunkte besitzt bereits bei einem Schwellwert von 0 ein niedriges Niveau (< 10). Die Anzahl der Validationspunkte sinkt deutlich durch die Steigerung des unteren Schwellwertes der relativen Häufigkeit. Bei einem Schwellwert von 1 werden nur noch 68.38 % der Validationspunkte verwendet die noch bei einem Schwellwert von 0 Anwendung finden. Die Klasse B27, W14 und W31 besitzen bereits bei einem Schwellwert von 0 sehr niedrige Werte (<10) bei der Anzahl an Validationspunkten (Tabelle 26). Bei einen Schwellwert von 1 sinken die Klassen B16, B23, B25, B26, B27, L14, W14 und W31 unteren den kritischen Wert (<10)( Tabelle 26). Die Aussagekraft der Ergebnisse dieser Klassen ist aufgrund der wenigen Validationspunkte stark eingeschränkt.




Abbildung 57: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Detailklassen.

Tabelle 26: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Detailklassen für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.80	0.89	0.85	37
B13	0.00	0.00	0.00	14
B16	1.00	0.95	0.97	20
B21	0.59	0.67	0.63	33
B23	0.39	0.41	0.40	17
B25	0.69	0.53	0.60	17
B26	0.93	0.46	0.62	28
B27	0.24	0.50	0.32	8
L11	0.95	0.87	0.91	148
L14	0.91	1.00	0.95	10
S10	0.72	0.95	0.82	65
S30	0.73	0.67	0.70	36
S50	0.75	0.60	0.67	25
W14	1.00	1.00	1.00	4
W21	1.00	1.00	1.00	12
W31	0.33	1.00	0.50	1
W40	0.64	0.87	0.74	31
Mittelwert / Summe	0.78	0.77	0.76	506
(b)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.79	0.90	0.84	30
B13	0.00	0.00	0.00	10
B16	1.00	1.00	1.00	2
B21	0.79	0.83	0.81	18
B23	0.40	1.00	0.57	2
B25	-	-	-	0
B26	0.00	0.00	0.00	3
B27	0.50	1.00	0.67	2
L11	1.00	0.96	0.98	112
L14	1.00	1.00	1.00	8
S10	0.76	0.97	0.85	62
S30	0.80	0.69	0.74	35
S50	0.83	0.60	0.70	25
W14	1.00	1.00	1.00	4
W21	1.00	1.00	1.00	12
W31	1.00	1.00	1.00	1
W40	0.83	0.95	0.88	20
Mittelwert / Summe	0.84	0.86	0.85	346






Abbildung 58: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.






Abbildung 59: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.




Abbildung 60: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Detailklassen.

### 6.3.3 Übertragbarkeitsdatensatz Rostock

Im Gegensatz zu den im vorangegangenen beschriebenen Datensätzen, finden bei dem Übertragbarkeitsdatensatz Rostock, basierend auf Sentinel-1 und Sentinel-2, auch multi-temporale Merkmale Anwendung. Im Bereich der Klassen der Hauptgruppe (Baumvegetation (B00), Grünland (L00), Gewässer (W00) und Siedlung und Infrastruktur (S00)) werden 86.75 % des gesamten Untersuchungsgebietes bei einem unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 klassifiziert bei einem Schwellwert von 1 werden 70.93 % klassifiziert (Tabelle 27). Die Klassifikationsergebnisse für den unteren Schwellwert von 0 sind in Abbildung 63, die für den Schwellwert 1 in Abbildung 64 und die Karte der relativen Häufigkeiten in Abbildung 65 dargestellt.

Tabelle 27: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Hauptgruppe.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.7593	0.8722	86.75
1.0	0.8457	0.9191	70.93

Der Kappa-Koeffizient steigt von 0.7593, die Gesamtgenauigkeit von 0.8457 bei einem Schwellwert von 0 auf 0.8722 respektive 0.9191 bei einem Schwellwert der relativen Häufigkeit von 1.




Abbildung 61: Konfusionsmatrizen für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).

Die Trefferquote schwankt je nach Klasse zwischen 0.68 und 0.91 bei einem Schwellwert von 0 und zwischen 0.81 und 0.94 bei einem Schwellwert von 1 (Abbildung 61, Tabelle 28). Zu größeren Fehlklassifikationen ( $> 0.05$ ) kommt es bei einem Schwellwert von 0 zwischen den Klassen Baumvegetation und Grünland (0.09), dem Grünland und der Baumvegetation (0.08), der Klasse Siedlung und Infrastruktur und dem Grünland (0.07) sowie der Gewässer-Klasse und dem Grünland (0.29). Bei einem Schwellwert von 1 kommt es zu größeren Fehlklassifikationen ( $> 0.05$ ) zwischen den Klassen Baumvegetation und Grünland (0.06), dem Grünland und der Baumvegetation (0.05) sowie der Gewässer-Klasse und dem Grünland (0.19) (Abbildung 61). Die Genauigkeit, die Trefferquote (Tabelle 28), das F-Maß (Tabelle 28, Abbildung 62), die Gesamtgenauigkeit und der Kappa-Koeffizient (Abbildung 62) steigen mit zunehmenden Schwellwert der relativen Häufigkeit an. Dagegen nimmt die Anzahl der Validationspunkte (Tabelle 28) und die klassifizierte Fläche (Abbildung 62) mit

zunehmenden Schwellwert der relativen Häufigkeit ab. Die relative und absolute Veränderung (Abnahme) der klassifizierten Fläche mit zunehmenden unteren Schwellwert der relativen Häufigkeit ist bei der Grünland-Klasse am stärksten (Abnahme um 26.79 %), gefolgt von der Baumvegetation (Abnahme um 25.55 %), der Siedlung und Infrastruktur (Abnahme um 6.08 %) und der Gewässer-Klasse (Abnahme um 2.05 %).

Tabelle 28: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Hauptgruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B00	0.96	0.88	0.92	1108
L00	0.69	0.91	0.79	323
S00	0.77	0.83	0.80	136
W00	0.94	0.68	0.79	92
Mittelwert / Summe	0.89	0.87	0.88	1659

(b)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B00	0.98	0.92	0.95	909
L00	0.79	0.94	0.86	265
S00	0.83	0.93	0.88	114
W00	0.94	0.81	0.87	72
Mittelwert / Summe	0.93	0.92	0.92	1360




Abbildung 62: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Hauptgruppe.






Abbildung 63: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.




Abbildung 64: Klassifikation für die Klassen der Hauptgruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.




Abbildung 65: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Hauptgruppe.



Die Ergebnisse der Klassen der Untergruppe (Laubbaumbestand (B11), Nadelbaumbestand (B16), Grün- und Grasland (L10), Landwirtschaftliche Nutzfläche (L20), Moor und Sumpf (W40), Offener Boden (R00) und Versiegelte Flächen (S10)) werden im Folgenden dargestellt. Die Gewässerbereiche (W00) aus der Hauptgruppe werden unverändert in die Untergruppe übernommen und deshalb nicht gesondert auf dieser Klassifikationsebene validiert. Die Klassifikationsergebnisse der Untergruppe für den Schwellwert 0 sind in Abbildung 68, für den Schwellwert 1 in Abbildung 69 und die Karte der relativen Häufigkeit für die Klassen der Untergruppe in Abbildung 70 dargestellt.

88.37 % der von den Klassen der Hauptgruppe maximal klassifizierten Fläche wird von Klassen der Untergruppe mit einem Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 abgedeckt (Tabelle 29, Abbildung 67). Bei einem Schwellwert von 1 sind es 47.69 % (Tabelle 29, Abbildung 67). Der Kappa-Koeffizient steigt von 0.815 auf 0.943 und die Gesamtgenauigkeit von 0.858 auf 0.957 (Tabelle 29).

Tabelle 29: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Klassen der Untergruppe.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.815	0.858	88.37
1.0	0.943	0.957	47.69

Die stärkste Flächenabnahme (96.29 %) verzeichnet die Klasse Offener Boden, gefolgt von der Moor- und Sumpf-Klasse (95.99 % Abnahme), der Laubbaumklasse (84.97 % Abnahme), der Nadelbaumklasse (72.34 % Abnahme), der Grün- und Graslandklasse (63.89 % Abnahme), der Landwirtschaftlichen Nutzfläche (51.19 % Abnahme) und der Versiegelten Fläche (21.72 % Abnahme). Die größten absoluten Flächenänderungen [km<sup>2</sup>] verzeichnet die Grün- und Graslandklasse, gefolgt von der Laubbaumklasse, der Landwirtschaftlichen Nutzfläche, der Nadelbaumklasse, der Versiegelten Fläche, dem Offenen Boden und der Moor- und Sumpf-Klasse.

Tabelle 30: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.79	0.88	0.83	196
B16	0.88	0.83	0.85	219
L10	0.87	0.93	0.90	228
L20	1.00	0.65	0.79	43
W40	0.40	0.24	0.30	17
R00	0.50	0.75	0.60	8
S10	0.97	0.92	0.94	112
Mittelwert / Summe	0.86	0.86	0.86	823
(b)				
Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.94	1.00	0.97	33
B16	1.00	0.99	0.99	73
L10	0.91	0.97	0.94	95
L20	1.00	0.88	0.93	16
W40	1.00	0.33	0.50	6
R00	1.00	1.00	1.00	2
S10	0.97	0.96	0.97	76
Mittelwert / Summe	0.96	0.96	0.95	301

Die Werte für die Genauigkeit, je Klasse, schwanken zwischen 0.40 und 1.0, für die Trefferquote zwischen 0.24 und 0.93 und für das F-Maß zwischen 0.3 und 0.94 für den Schwellwert von 0 (Tabelle 30 a). Für den Schwellwert von 1 schwanken die Werte für die Genauigkeit zwischen 0.91 und 1.0, für die Trefferquote zwischen 0.33 und 1 und für das F-Maß zwischen 0.5 und 1.0 (Tabelle 30 b).




Abbildung 66: Konfusionsmatrizen für die Klassifikationsergebnisse der Untergruppe für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) respektive 1 (b).




Abbildung 67: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Klassen der Untergruppe.

Die größten Fehlklassifikationen ( $> 0.05$ ) bei einem Schwellwert von 0 treten zwischen der Laubbaumklasse und der Nadelbaumklasse (0.11), der Nadelbaumklasse (B16) und der Laubbaumklasse (0.16), der Klasse der Landwirtschaftlichen Nutzflächen (L20) mit dem Grünland

(0.33), der Moor und Sumpf-Klasse (W40) mit dem Grünland (0.65) und der Laubbaumklasse (0.12) sowie dem Offenen Boden (0.09) mit dem Grünland (0.25) auf (Abbildung 66 a). Bei einem Schwellwert von 1 gibt es nur noch größere Fehlklassifikationen ( $> 0.05$ ) zwischen der Landwirtschaftlichen Nutzflächen (L20) und dem Grünland (0.12) sowie der Moor und Sumpf-Klasse (W40) mit dem Grünland (0.67) (Abbildung 66 b). Auffällig ist die starke Fehlklassifikation im Bereich der Moor- und Sumpf-Klasse.

Die zunehmende Gesamtgenauigkeit, der zunehmende Kappa-Koeffizient und das steigende F-Maß bei abnehmender klassifizierter Fläche und abnehmender Anzahl an Validationspunkten ist auch hier zu beobachten (Tabelle 30, Abbildung 67). Bei den Validationspunkten werden bei einem Schwellwert der relativen Häufigkeit von 1 nur noch 36.57 % der Validationspunkte des Schwellwertes 0 der relativen Häufigkeit verwendet (Tabelle 30). Unter das kritische Niveau der Anzahl an Validationspunkten ( $< 10$ ) fällt der Offener Boden bei einem Schwellwert der relativen Häufigkeit von 0 und die Klassen Sumpf und Moor und Offener Boden bei einem Schwellwert der relativen Häufigkeit von 1. Bei diesen Klassen sind die Ergebnisse nur noch bedingt aussagekräftig.




Abbildung 68: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.




Abbildung 69: Klassifikation für die Klassen der Untergruppe anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.






Abbildung 70: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Klassen der Untergruppe.



Als Detailklassen werden die Klassen Laubwald (B11), Laubmischwald (B13), Mischwald (B14), Nadelmischwald (B15), Nadelwald (B16), Feldgehölz / Baumgruppe (B21), Baumreihe (B23), Solitär (B25), Hecke (B26), Gebüsch (B27), Feuchtgrünland (L11), Frisches Grünland (L12), Trockengrünland (L14), Salzgrasland (L15), Ruderal- und Staudenfluren (W40), Wohn- und Mischgebiet (S10), Gewerbegebiet (S30), Verkehrsflächen (S50), Fluss (W21) und See (W31) klassifiziert. Die Klasse Landwirtschaftliche Nutzfläche wird aus den Untergruppe unverändert übernommen und deshalb nicht bei den Detailklassen validiert. Die Ergebnisse für die Klassifikation der Detailklassen anhand eines unteren Schwellwertes der relativen Häufigkeit von 0 ist in Abbildung 72, eines unteren Schwellwertes der relativen Häufigkeit von 1 in Abbildung 73 und die Verteilung der relativen Häufigkeit in Abbildung 74 dargestellt.




Abbildung 71: Gesamtgenauigkeit (a), Kappa-Koeffizient (b), F-Maß (c) und klassifizierte Fläche (a,b,c) in Abhängigkeit von der relativen Häufigkeit sowie F-Maßverteilung (d) für die Detailklassen.

Tabelle 31: Kappa-Koeffizient, Gesamtgenauigkeit und klassifizierte Fläche für die Detailklassen.

Schwellwert (relative Häufigkeit)	Kappa	Gesamtgenauigkeit	Klassifizierte Fläche [%]
0.0	0.511	0.549	77.29
1.0	0.666	0.704	38.18

Tabelle 32: Genauigkeit, Trefferquote, F-Maß und Anzahl der Validationspunkte für die Klassifikationsergebnisse der Detailklassen für den unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für das Hinzufügen der Validationspunkte von 0 (a) beziehungsweise 1 (b).

(a)

Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.65	0.72	0.68	197
B13	0.58	0.48	0.53	58
B14	0.65	0.41	0.50	88
B15	0.42	0.14	0.21	127
B16	0.59	0.57	0.58	219
B21	0.27	0.74	0.40	103
B23	0.54	0.46	0.50	110
B25	0.38	0.20	0.26	15
B26	0.00	0.00	0.00	21
B27	0.91	0.21	0.34	96
L11	0.53	0.77	0.63	61
L12	0.63	0.64	0.63	88
L14	0.71	0.56	0.63	45
L15	0.79	1.00	0.88	15
S10	0.75	0.54	0.63	76
S30	0.52	0.87	0.65	39
S50	0.52	1.00	0.68	39
W21	0.96	0.69	0.81	36
W31	0.71	1.00	0.83	27
W40	0.75	0.23	0.35	13
Mittelwert / Summe	0.59	0.55	0.53	1473

(b)

Klasse	Genauigkeit	Trefferquote	F-Maß	# Validationspunkte
B11	0.73	0.99	0.84	86
B13	0.50	0.38	0.43	8
B14	1.00	0.44	0.62	18
B15	0.00	0.00	0.00	40
B16	0.57	0.80	0.67	69
B21	0.46	0.95	0.62	19
B23	0.50	0.33	0.40	12
B25	1.00	1.00	1.00	1
B26	0.00	0.00	0.00	3
B27	1.00	0.05	0.10	20
L11	1.00	0.43	0.60	7
L12	1.00	0.50	0.67	8
L14	1.00	0.50	0.67	2
L15	1.00	1.00	1.00	2
S10	0.94	0.62	0.74	26
S30	0.69	0.85	0.76	26
S50	0.81	1.00	0.90	39
W21	0.96	0.88	0.92	26
W31	0.73	1.00	0.84	27
W40	0.00	0.00	0.00	4
Mittelwert / Summe	0.67	0.70	0.65	443

Im Bereich der Detailklassen werden 77.29 % der maximal bei den Klassen der Untergruppe klassifizierten Flächen bei einem unteren Schwellwert der relativen Häufigkeit von 0 erfasst. Bei einem Schwellwert der relativen Häufigkeit von 1 werden 38.18 % erfasst (Tabelle 31).

Die Gesamtgenauigkeit steigt von 0.549 auf 0.704 und der Kappa-Koeffizient von 0.511 auf 0.666 bei einer Veränderung des Schwellwertes der relativen Häufigkeit von 0 auf 1 (Tabelle 31). Die geringeren Veränderungen im Bereich der Genauigkeiten (Abbildung 71 a / b) ist auf die Klassen basierend auf den harten Merkmalen zurückzuführen, da diese nicht so stark von den relativen Häufigkeiten beeinflusst werden wie die Klassen basierend auf den weichen Merkmalen. Dies gilt vor allem für die Waldklassen und die Siedlungsklassen, da diese zwar basierend auf den Ergebnissen der Hauptgruppe klassifiziert werden, die finalen Objekte jedoch auf den städtischen Blockobjekten und den Waldbestandsgrenzen der Biotoptypenkartierung beruhen. Die Klassen basierend auf den harten Merkmalen bilden mit 16 von 20 Klassen den überwiegenden Teil der Detailklassen.

Die Genauigkeit variiert zwischen den Klassen stark im Bereich von 0.0 (B26) und 0.96 (W21), die Trefferquote variiert zwischen 0.0 (B26) und 1.0 (L15, S50 und W31) und das F-Maß variiert zwischen 0.0 (B26) und 0.88 (L15). Die Anzahl der Validationspunkte sinkt deutlich durch die Steigerung des unteren Schwellwertes der relativen Häufigkeit. Bei einem Schwellwert von 1 werden nur noch 30.07 % (433) der Validationspunkte verwendet die noch bei einem Schwellwert von 0 (1473) Anwendung finden. Die Klassen B13, B25, B26, L11, L12, L14, L15 und W40 sinken auf sehr niedrige Werte (<10) (Tabelle 32). Die Aussagekraft der Ergebnisse dieser Klassen ist aufgrund der wenigen Validationspunkte stark eingeschränkt.




Abbildung 72: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 0.




Abbildung 73: Klassifikation der Detailklassen anhand eines unteren Schwellwert der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes von 1.






Abbildung 74: Karte der relativen Häufigkeit für die Klassenzusammenlegung beziehungsweise für Hinzufügen des Validationspunktes für die Detailklassen.



## 6.4 Synergieeffekte

Die in Kapitel 5.4 beschriebenen und für die Klassen basierend auf weichen Merkmalen für das Entwicklungsgebiet Rostock analysierten Synergieeffekte werden im folgenden ebenenweise betrachtet. Abbildung 75 zeigt die Veränderung des F-Maßes je Klasse der Hauptgruppe basierend auf den unterschiedlichen Merkmalskategorien beziehungsweise Kombinationen der Merkmalskategorien.




Abbildung 75: Veränderung des F-Maßes durch Synergieeffekte der Klassen der Hauptgruppe basierend auf weichen Merkmalen.

Die niedrigsten Werte (F-Maß), mit Klassen unter einen Wert von 0.8, treten bei der Verwendung der SAR-Merkmalskategorie (0.56 / Mittelwert = 0.685), gefolgt von der Kombination SAR/GEO (0.77 / Mittelwert = 0.845) auf. Merkmalskategorien und Kombinationen von Merkmalskategorien mit Klassen über 0.8 aber unter 0.9 sind MS (0.83 / Mittelwert = 0.905), MS/SAR (0.83 / Mittelwert = 0.908) und MS/GEO (0.89 / Mittelwert = 0.9225). Die verbleibenden Kombinationen der Merkmalskategorien (Alle M./Vorklas./rH0 und Alle M./Vorklas./rH1) erreichen minimale F-Maß Werte von  $\geq 0.9$  mit Mittelwerten von 0.943 respektive 0.973.




Abbildung 76: Veränderung des F-Maßes durch Synergieeffekte der Klassen der Untergruppe basierend auf weichen Merkmalen.

Abbildung 76 zeigt die Veränderung des F-Maßes je Klasse der Untergruppe basierend auf den unterschiedlichen Merkmalskategorien beziehungsweise Kombinationen der Merkmalskategorien. Wie in Kapitel 6.3.1 beschrieben, weichen die beiden Klassen Offener Boden (R00) und Moor und Sumpf

(W40) von den restlichen Klassen der Untergruppe in ihrer Repräsentation durch das F-Maß ab. Während die Klasse W40 in den Kombinationen der Merkmalskategorien *Alle M./Vorklas./rH0* (0.36) und *Alle M./Vorklas./rH1* (0.46) den niedrigsten Wert des F-Maß zeigt, zeigen die verbleibenden Klassen bei der Kombination der Merkmalskategorien *Alle M./Vorklas./rH1* die höchsten Werte ( $\geq 0.95$ ). Diese Kombination der Merkmalskategorien erreicht über alle Klassen den höchsten Wert (Mittelwert = 0.89). Betrachtet man alle Klassen der Untergruppe erreicht die Merkmalskategorie SAR (Mittelwert = 0.726) die geringsten Werte und wird gefolgt von der Kombination der Merkmalskategorien SAR/GEO (Mittelwert = 0.737).




Abbildung 77: Veränderung des F-Maßes durch Synergieeffekte der Detailklassen basierend auf weichen Merkmalen.

Die Ergebnisse für die Detailklassen sind in Abbildung 77 dargestellt. Die Kombination der Merkmalskategorien SAR/GEO erzielt die niedrigsten Werte des F-Maß (Mittelwert = 0.532), gefolgt von der Merkmalskategorie SAR (Mittelwert = 0.56). Die besten Ergebnisse werden von der Kombination der Merkmalskategorien *Alle M./Vorklas./rH1* (Mittelwert = 0.854) erreicht, gefolgt von der MS Merkmalskategorie (Mittelwert = 0.832).

Abbildung 78 stellt die beschriebenen Ergebnisse unabhängig der Klassifikationsebenen dar (Klassen 1-4 = Hauptgruppe, Klassen 5-11 = Untergruppe und Klassen 12-16 = Detailklassen).




Abbildung 78: Veränderung des F-Maßes durch Synergieeffekte aller Klassen basierend auf weichen Merkmalen.

# 7 Zusammenfassung und Diskussion

---

*Wo kämen wir hin, wenn alle sagten, wo kämen wir hin, und niemand ginge, einmal zu schauen, wohin man käme, wenn man ginge.*

Kurt Marti (2003): *Der Traum, geboren zu sein*. Ausgewählte Gedichte. Nagel & Kimche im Hanser Verlag.

---

Die Kartierung von Biotoptypen bildet eine entscheidende Grundlage um alle Biotop- und Landnutzungstypen nachhaltig behandeln zu können und den Erhalt der Biodiversität zu gewährleisten beziehungsweise die Biodiversität regional zu erhöhen (QUI ET AL., 2010). In der vorliegenden Arbeit wurde untersucht, inwieweit die Verwendung von synergistischen Fernerkundungsdaten und die Entwicklung einer objekt-basierten, auf der Merkmalsauswahl beruhenden Klassifikationsmethode die traditionellen Kartierbemühungen unterstützen kann. Nach einer kurzen Einführung in die Fernerkundung, Klassifikation und der Definition der relevanten Begrifflichkeiten wurden im Stand der Forschung die traditionellen Kartiermethoden, nationale und internationale Monitoringansätze und Klassifikationssysteme, die Merkmalsauswahl, die bisher in der Literatur erschienen Ansätze zur Kartierung von Biotoptypen mittels Fernerkundung sowie die Datenbasis betrachtet. Im vorliegenden Kapitel werden die verwendeten Methoden und erzielten Ergebnisse diskutiert.

Das Methodenkapitel ist unterteilt in die Erzeugung der Wissensbasis, Methodik der Merkmalsauswahl, Klassifikationsansatz und Synergie.

Im Kapitel *Erzeugung der Wissensbasis* wurden anhand der Literatur im Bereich der Biotoptypenkartierung Merkmale erzeugbar aus den vorhandenen Satellitendaten zusammengetragen und beschrieben (Kapitel 5.1.1 und Kapitel 5.1.2) und die Forschungsfrage *Welche Merkmale und Merkmalskategorien lassen sich aus den vorhandenen Fernerkundungsdaten erzeugen?* beantwortet. Da im Bereich der Kartierung von Biotoptypen mittels Fernerkundungsdaten bis zum jetzigen Zeitpunkt nur eine begrenzte Anzahl an Veröffentlichungen vorliegt, wurde die Suche nach potenziellen Merkmalen auf Veröffentlichungen im Bereich der Landbedeckungs- und Landnutzungsklassifikation, der urbanen Klassifikation sowie der Klassifikation von Feldfrüchten beziehungsweise landwirtschaftlichen Nutzflächen ausgedehnt.

Die ermittelten Merkmale wurden in thematische Kategorien unterteilt und für die Evaluation der Synergie hauptsächlich anhand ihrer Ursprungsdatenquelle weiter aggregiert. Dies führte sowohl zu einem zahlenmäßigen Ungleichgewicht zwischen den Merkmalskategorien als auch innerhalb einer Merkmalskategorie für die unterschiedlichen Testgebiete (z.B. spektrale Merkmale basierend auf RapidEye (Entwicklungsdatensatz Rostock) und die spektralen Merkmale basierend auf Sentinel-2 (Übertragbarkeitsdatensatz Rostock)). Die Effekte dieses Ungleichgewichtes sind an dieser Stelle nicht zu evaluieren, aber in der weiteren Verarbeitung der Merkmale sicherlich vorhanden.

Im Kapitel *Erwartete Merkmale der Biotoptypen* wurden Informationen über die erwarteten Merkmalsausprägungen für die Klassen der Hauptgruppen und teilweise der Klassen der Untergruppen und der Detailklassen zusammengetragen. Die Informationslage hängt stark von der Merkmalskategorie und der Klasse ab. Für die spektralen Merkmale konnten verfügbare Datenbanken des *United States Geological Survey* (USGS) (CLARK ET AL., 2007) verwendet werden. Für die Definition geometrischer und relationaler Merkmale konnte auf die Definition der Landesämter (LUNG, 2010, LfULG, 2010) zurückgegriffen werden. Für die Merkmale im Bereich Textur und SAR konnten keine

Datenbanken ermittelt werden und die erwarteten Merkmalsausprägungen nur anhand von einzelnen Veröffentlichungen dargestellt werden. Im Bereich der spektralen Transformationen und der multi-temporalen Merkmale sind keine Aussagen möglich, da die resultierenden Merkmale stark von der Statistik der eingehenden Szenen abhängig sind.

Die Werte der Pixel pro Kanal im Satellitenbild bilden durch die Abdeckung mehrerer Nanometer lediglich eine Approximation an die in-situ gemessenen (z.B. spektralen) Werte. Nichtsdestotrotz können die ermittelten blauen, grünen, roten und nahen infraroten Reflexionsbereiche als erwartete Merkmalsbereiche betrachtet werden. Durch die hohe Variation im rededge Kanal sind hier keine Aussagen zu den erwarteten Werten möglich.

Zu beachten ist weiterhin der Aufnahmezeitpunkt der Satellitenszene, da je nach Vegetationsart und Jahreszeit die Reflexion stark variieren kann (BLACKBURN UND MILTON, 1995, KODANI ET AL., 2002, ZHANG ET AL., 2006). Wie in Abbildung 79 zu erkennen, werden die höchsten Reflexionen für eine Buchenart zwischen Mai und Juli, mit einem Maximum im Juni, erreicht. Dies bedeutet nicht zwangsläufig, dass diese Klasse zu dieser Jahreszeit auch am besten von anderen Klassen trennbar ist. Anhand der Merkmale zur Trennung der Laubbaumbestände und der Nadelbaumbestände des Übertragbarkeitsdatensatzes Rostock basierend auf den ganzjährigen Sentinel-1 und Sentinel-2 Daten zeigt sich jedoch, dass zusätzlich zu zwei multi-temporalen Merkmalen, acht der zwölf verwendeten Merkmale (66.66 %) aus dem Zeitraum 30.04.2017 bis 30.08.2017 stammen (Tabelle A 6). Betrachtet man die Merkmalsauswahl ohne die multi-temporalen Merkmale, stammen zehn der dreizehn verwendeten Merkmale (76.92 %) aus dem Zeitraum 30.04.2017 bis 30.08.2017 (Tabelle A 5).




Abbildung 79: Variation der Reflexion (380-880 nm) einer Buchenart im Zeitraum von April bis November (Quelle: Kodani et al, 2002).

Die räumliche Auflösung der verwendeten Daten im Bereich von 5 m bis 10 m führt in einer Vielzahl von Fällen zu Mischpixeln. Für großflächige, dichte Bestände ergeben sich hieraus keine großen Probleme. Bei kleinräumigen oder lockeren Beständen können z.B. Boden- oder Schattenanteile im Signal zu starken Abweichungen der Werte führen. Dies wiederum erschwert die Zuordnung der Pixel zur Biotoptypengruppe. Die Erfassung von einzelnen Baumkronen in einem Baumbestand ist auf dieser Auflösungsebene nicht möglich. Die Detektion von Einzelbäumen im Kontext der Landschaftselemente ist jedoch, bei deutlicher spektraler Abgrenzung von der Umgebung, möglich.

Im Kapitel *Auswahl der Trennbarkeitsmaße* wird die Forschungsfrage *Welche Methode eignet sich zur Merkmalsauswahl?* beantwortet. Hierfür wurden, basierend auf der Literaturrecherche aus Kapitel 3.5, Trennbarkeitsmaße aus den verschiedenen Kategorien selektiert und mittels eines eigens dafür definierten Drei-Klassen-Problems ihre Eignung für das Merkmalsranking evaluiert. Durch die Vielzahl der in der Literatur vorhandenen Trennbarkeitsmaße und die in der vorliegenden Arbeit durchgeführte

Reduktion auf eine Auswahl ist nicht auszuschließen, dass potenziell besser geeignete Maße nicht mit in die Auswahl aufgenommen worden.

Das Drei-Klassen-Problem, auch wenn es sich aus zwei Klassen der Hauptgruppe (Gewässer und Grünland) sowie einer Klasse der Untergruppe (Laubbaumbestand) und somit einer Vielzahl der möglichen Merkmalsausprägungen zusammensetzt, hat einen starken Einfluss auf das Ergebnis der Auswahl des bestmöglichen Trennbarkeitsmaßes. Die Verwendung zum Beispiel der vier Klassen der Hauptgruppe würde das Problem jedoch zu komplex werden lassen und ein Ranking der Merkmale a priori nicht mehr zulassen.

Das resultierende Ergebnis und die Wahl der *Support Vector Machine* (SVM) als Methode für das Merkmalsranking findet Bestätigung in der Literatur (GUYON ET AL., 2002, LI ET AL., 2016, OLSEN ET AL., 2017). Die Definition des Kernels und dessen Parameter für die SVM findet im Kapitel *Merkmalsranking* anhand der Klassen der Hauptgruppe statt. Der *radial basis function* (rbf) Kernel liefert die besten Ergebnisse und findet regelmäßig Anwendung in der Literatur (GARCIA ET AL., 2011, LI ET AL., 2016, MACK ET AL., 2016, POLYCHRONAKI ET AL., 2015). Einer Tendenz zu einer Überanpassung der Methode an die Trainingsdaten (Abbildung 20) wird entgegengewirkt, indem die Eingangsdaten normalisiert und in 80 % Trainingsdaten und 20 % Validationsdaten geteilt werden (Kapitel 5.3.1).

Die Selektion (Kapitel 5.3.4) des im weiteren Verlauf dieses Kapitels noch diskutierten *Random Forest* (RF) als Methode für die Merkmalsreduktion und die Klassifikation ist konsequent, um die Vorteile der Methode und die selektierten Merkmale optimal in der Klassifikation nutzen zu können. GERON, 2017 vermerkt z. B., dass *Decision Trees*, welche die Grundlage für den *Random Forest* bilden, sensitiv gegenüber der Ausrichtung beziehungsweise Rotation der Merkmale sind. So können Trennungen deutlich einfacher orthogonal vorgenommen werden. Dies gilt dann zugleich für die Merkmalsreduktion wie auch für die Klassifikation.

Im Kapitel *Klassifikationsansatz* wurden die Segmentierungsmethode, die Klassifikationsmethode, der Klassifikationsablauf, die Erstellung des Häufigkeitsdatensatzes, die Klassenzusammenlegung, die Übertragbarkeit und die Genauigkeitsanalyse beschrieben und die Forschungsfrage *Welche Klassifikationsmethode eignet sich für die Erfassung von Biotoptypen?* beantwortet.

Laut MA ET AL., 2017 ist die in der vorliegenden Arbeit verwendete *Multiresolution Segmentation* (MRS) mit 80.9 %, aus 254 betrachteten Studien, die häufigste Segmentierungsmethode im Bereich der objektbasierten Landbedeckungsklassifikation und somit eine etablierte Methode. Maßgeblich für die resultierenden Objekte ist die bestmögliche Definition des *Scale Parameters*. Durch die abstrakte Natur des *Scale Parameters* wurden mittels des *Estimation of Scale Parameters* (ESP) Programm (DRĂGUȚ ET AL., 2010), welches die Veränderung der lokalen Varianz der Objekte zueinander betrachtet, optimale Werte für den *Scale Parameter*, unter Berücksichtigung der vorliegenden Daten und Referenzobjekte, gesucht. Die resultierenden *Scale Parameter* spiegelten sowohl kleine im Entwicklungsdatensatz vorhandene Objekte (z.B. Häuser und Solitäre) wie auch homogene, großflächige Strukturen (z.B. Grünland) wieder. Um einen Kompromiss aus Anwendbarkeit und Genauigkeit zu finden, wurde anhand des lokalen Maximum aus den fünf benachbarten Werten die sechs resultierenden *Scale Parameter* für die Segmentierung selektiert. Ein geringerer Suchradius für das lokale Maximum hätte mehr, ein größerer Suchradius hätte weniger *Scale Parameter* selektiert. Der Einfluss weiterer oder weniger Segmentierungsebenen und somit Klassifikationsebenen kann an dieser Stelle nicht beurteilt werden und muss Gegenstand weiterer Untersuchungen sein.

Die Auswahl des *Random Forest* als Klassifikations- und Merkmalsreduktionsmethode beruht auf der erfolgreichen Anwendung in einer Vielzahl von Veröffentlichungen mit dem Inhalt der Kartierung von Vegetation mittels hoch und sehr hoch aufgelöster Satellitendaten (BERHANE ET AL., 2018, BARRETT ET AL., 2016, DURO ET AL., 2012, FEILHAUER ET AL., 2014, GOSH & JOSHI, 2014, IMMITZER ET AL., 2012, KASZTA ET AL., 2016, LI ET AL., 2016, LÖW ET AL., 2015, LOWE & KULKARNI, 2015, MA ET AL., 2017). Die Auswahl der optimalen Parameter anhand der Klassen der Hauptgruppe bildet die Grundlage für die weitere Anwendung der Methode. Lediglich bei der Auswahl der Baumtiefe wurde ein Kompromiss zwischen

Laufzeit des Algorithmus (12 gegen 408 [min./Klasse]) und der Genauigkeit (0.9325 gegen 0.9375 [Mittelwert F-Maß der Klassen der Hauptgruppe]) eingegangen. Das empirische Design des Klassifikationsablaufes und die Unterteilung der Klassen in *basierend auf weichen Merkmalen* und *basierend auf harten Merkmalen* fußt auf der Klassenbeschreibung der Kartieranleitungen der Länder (LUNG, 2010, LFULG, 2010). Der Klassifikationsablauf ist darauf ausgelegt, basierend auf den sechs Segmentierungsergebnissen und der ebenen- und klassenweisen *Random Forest* Klassifikation, in einer *decision level fusion* (DONG ET AL., 2009, RASTIVEIS, 2015, POHL & VAN GENDEREN, 1998, ZENG ET AL., 2006) zu münden. Im Unterschied zur *data level fusion*, der Fusion der Satellitendaten auf Pixelebene, oder *feature level fusion*, der Fusion der extrahierten Merkmale, werden bei der *data level fusion* die Ergebnisse, im Fall der vorliegenden Arbeit die Klassifikationen, in ein Klassifikationsergebnis zusammengefasst (POHL & VAN GENDEREN, 1998). Dies geschieht regelbasiert und ebenenweise (Kapitel 5.2.5). Dem einfachen, regelbasierten Vorgehen wird der Vorrang gegenüber komplexeren Methoden wie z.B. *Neuronalen Netzwerken*, *Bayesian Inference* oder der *Dempster-Shafer's Methode* (ZENG ET AL., 2006) gegeben. Ein Vergleich der Methoden für die *decision level fusion* und deren Einfluss auf das Klassifikationsergebnis, über den an dieser Stelle keine Einschätzung möglich ist, muss in weiteren Untersuchungen erfolgen. Der bei der Klassenzusammenlegung erstellte Häufigkeitsdatensatz erzeugt eine weitere Informationsebene auf Pixelbasis über die Güte der Klassifikation. Der Häufigkeitsdatensatz wird dahingehend interpretiert, dass hohe Werte ( $> 0.7$ ) im Häufigkeitsdatensatz auf eine gesteigerte Klassifikationsgenauigkeit und niedrige Werte ( $< 0.3$ ) auf eine geringe Klassifikationsgenauigkeit hindeuten. Die Klassifikationsgenauigkeit wird ausgedrückt durch die in der Literatur zur Biototypen-, Landbedeckungs- und Landnutzungsklassifikation breite Anwendung findenden Maße: Kappa-Koeffizienten (COHEN, 1960, FOODY, 2002, HAEST ET AL., 2017, IMMITZER ET AL., 2016, O'CONNELL ET AL., 2015, SCHULTZ ET AL., 2015, ZLINSZKY ET AL., 2014), Gesamtgenauigkeit (FOODY, 2002, HAEST ET AL., 2017, IMMITZER ET AL., 2016, LI ET AL., 2016, O'CONNELL ET AL., 2015, SCHULTZ ET AL., 2015, ZLINSZKY ET AL., 2014) und das F-Maß (BOGNER ET AL., 2018, HORVAT ET AL., 2016, LU ET AL., 2014, O'CONNELL ET AL., 2015, POWERS, 2011).

Das Ergebniskapitel ist unterteilt in die Ergebnisse der Merkmalsauswahl, die Evaluation der Segmentierung, die Klassifikationsergebnisse und die Genauigkeitsanalyse sowie die Darstellung der Synergieeffekte.

MA ET AL., 2017 halten fest, dass die *Merkmalsauswahl* ein wichtiger Schritt innerhalb eines Klassifikationsprozesses ist, um die Komplexität der Klassifikation zu reduzieren und redundante Merkmalsinformationen zu entfernen. Allerdings wird in den von MA ET AL., 2017 untersuchten 254 Studien zur objekt-basierten Landbedeckungsklassifikation lediglich in 22 % eine Merkmalsauswahl durchgeführt. In 61 % der Studien wird die Merkmalsauswahl entweder nicht angewendet oder nicht explizit genannt. In einer geringen Anzahl der untersuchten Studien (DURIC ET AL., 2014, KIM & YEOM, 2014, MAXWELL ET AL., 2015) werden manuell Merkmalskombinationen von den Autoren selektiert (MA ET AL., 2017).

Für das Entwicklungsgebiet Rostock konnten die benötigten Merkmale für die Klassifikation je Klasse von 318 potenziellen Merkmalen auf ein bis 13 Merkmal(e) je Klasse reduziert werden. Es wurden 94 Merkmale für die Klassifikation der 16 Klassen basierend auf den weichen Merkmalen aus den insgesamt 5088 (16 Klassen je 318 Merkmale) potenziellen Merkmalen verwendet. Welches einer Reduktion von 98.153 % entspricht. Dies führt zu einer massiven Reduktion von benötigtem Speicherplatz und benötigter Rechenleistung. Für das Übertragbarkeitsgebiet Groitzsch wurden 248 potenzielle Merkmale je Klasse erzeugt. 68 Merkmale wurden für die 14 Klassen basierend auf weichen Merkmalen für die Klassifikation verwendet. Es wurden zwischen einem Merkmal und zehn Merkmalen je Klasse verwendet. Die 68 Merkmale entsprechen einer Reduktion von 98.041 % der potenziellen 3472 Merkmale (14 Klassen je 248 Merkmale). Für das auf den Sentinel-1 und Sentinel-2-Daten beruhende Übertragbarkeitsgebiet Rostock wurden 2081 potenzielle Merkmale je Klasse erzeugt. Diese gegenüber den anderen Datensätzen deutlich gesteigerte Anzahl an Merkmalen ist der höheren



zeitlichen Dichte der Aufnahmen und zu einem geringen Anteil der zusätzlichen Verwendung der multi-temporalen Merkmale geschuldet. Für die 16 auf den weichen Merkmalen beruhenden Klassen wurden 115 Merkmale der möglichen 32288 Merkmale (16 Klasse je 2081 Merkmale) verwendet. Dies entspricht einer Reduktion von 99.644 %. Pro Klasse kamen zwischen einem Merkmal und 15 Merkmale zur Anwendung. Die Genauigkeit, im Zuge der *Random Forest* Klassifikation für die Merkmalsauswahl, bleibt in einigen Fällen gleich und steigt in den meisten Fällen durch die Verwendung nur der selektierten Merkmale im Vergleich zur Verwendung aller Merkmale an.




Abbildung 80: Vergleich des anhand des *Random Forest* erzielten F-Maß mit und ohne Merkmalsauswahl für den Entwicklungsdatensatz Rostock und die Übertragbarkeitsdatensätze Rostock und Groitzsch.






Abbildung 81: Zusammenhang zwischen der Anzahl der Trainingspunkte und dem resultierenden F-Maß für die Klassen der Hauptgruppe.

Abbildung 80 zeigt das erzielte F-Maß für die maximal 16 Klassen basierend auf den weichen Merkmalen für den Entwicklungsdatensatz Rostock und die beiden Übertragbarkeitsdatensätze Groitzsch und Rostock. In keinen der Fälle liegt das F-Maß basierend auf allen Merkmalen höher als bei der Verwendung nur der Merkmale aus der Merkmalsauswahl. Somit kann festgehalten werden, dass die Merkmalsauswahl nicht nur die Komplexität der Klassifikation reduziert und redundante Merkmalsinformationen entfernt, sondern auch die erreichbare Klassifikationsgenauigkeit erhöht. Dies deckt sich mit den Ergebnissen der Untersuchungen von GUYON ET AL., 2002, PAL & FOODY, 2010 und TAN, 2007.



Die Abbildung 81, Abbildung 82 und Abbildung 83 zeigen den Zusammenhang zwischen dem aus der Klassifikation resultierenden F-Maß und der Anzahl der verwendeten Trainingspunkte für alle relativen Häufigkeiten und Untersuchungsgebiete.

Ein leicht positiver Effekt kann bei der Steigerung der Anzahl der Trainingspunkte bei der Merkmalsauswahl auf die resultierte Genauigkeit (F-Maß) beobachtet werden (Abbildung 81, Abbildung 82, Abbildung 83). Die Streuung des F-Maß je Klasse nimmt dagegen mit steigender Anzahl an Trainingspunkten ab (Abbildung 81, Abbildung 82, Abbildung 83). Keinen Einfluss hat die Anzahl der Trainingspunkte auf die Anzahl der resultierenden Merkmale je Klasse. Somit gilt, dass, bei der vorgestellten Merkmalsauswahl, eine Steigerung der Trainingspunkte zu einer leichten Steigerung der resultierenden Klassifikationsgüte und einer Verringerung der Streuung innerhalb der resultierenden Genauigkeiten führt.

Im Bereich der *Klassifikationsergebnisse* werden im Folgenden die Ergebnisse der drei verwendeten Datensätze miteinander und zusätzlich mit Ergebnissen aus der Literatur verglichen. Abbildung 84 zeigt den Vergleich der Gesamtgenauigkeit, des Kappa-Koeffizienten und der klassifizierten Fläche ([%] skaliert zwischen 0 und 1) bezogen auf die auf der vorangegangenen Klassenebene maximal klassifizierte Fläche in Abhängigkeit von der relativen Häufigkeit (0 beziehungsweise 1), der Klassifikationsebene sowie dem Untersuchungsgebiet. Ein Vergleich der Gesamtgenauigkeit zwischen dem Entwicklungsdatensatz Rostock und den Übertragbarkeitsdatensätzen Groitzsch und Rostock zeigt keine großen ( $> 0.1$ ) absoluten Abweichungen für die Klassen der Haupt- und Untergruppe. Lediglich bei den Detailklassen sind für den Übertragbarkeitsdatensatz Rostock und einer relativen Häufigkeit von 0 größere ( $> 0.1$ ) absolute Abweichungen bei der Gesamtgenauigkeit sichtbar. Das gleiche Bild zeigt sich bei den Werten des Kappa-Koeffizienten. Bei der klassifizierten Fläche zeigt sich eine größere ( $> 0.1$ ) absolute Abweichung zwischen dem Entwicklungsdatensatz Rostock und dem Übertragbarkeitsdatensatz Rostock und einer relativen Häufigkeit von 1.




Abbildung 84: Vergleich der Gesamtgenauigkeit, des Kappa-Koeffizienten und der klassifizierten Fläche in Abhängigkeit von der relativen Häufigkeit (0 und 1), der Klassifikationsebene sowie dem Untersuchungsgebiet.

Die Gesamtgenauigkeit liegt zwischen 87.22 % (Übertragbarkeitsdatensatz Rostock mit einer relativen Häufigkeit von 0) und 98.1 % (Übertragbarkeitsdatensatz Groitzsch mit einer relativen Häufigkeit von 1) für die vier Klassen der Hauptgruppe (Abbildung 84). Bei den sieben Klassen der Untergruppe liegt die Gesamtgenauigkeit zwischen 85.6 % (Entwicklungsdatensatz Rostock mit einer relativen Häufigkeit

von 0) und 99.1 % (Übertragbarkeitsdatensatz Groitzsch mit einer relativen Häufigkeit von 1) (Abbildung 84). Der Kappa-Koeffizient erreicht bei den vier Klassen der Hauptgruppe Werte von 0.7593 (Übertragbarkeitsdatensatz Rostock mit einer relativen Häufigkeit von 0) bis 0.971 (Übertragbarkeitsdatensatz Groitzsch mit einer relativen Häufigkeit von 1) (Abbildung 84). Für die sieben Klassen der Untergruppe werden Werte des Kappa-Koeffizienten zwischen 0.815 (Übertragbarkeitsdatensatz Rostock mit einer relativen Häufigkeit von 0) und 0.987 (Übertragbarkeitsdatensatz Groitzsch mit einer relativen Häufigkeit von 1) erreicht (Abbildung 84).

Verglichen mit Werten aus der Literatur wurden somit gute bis sehr gute Ergebnisse erzielt. So erreichen DURIC ET AL., 2014 bei der objekt-basierten Klassifikation von vier Landbedeckungsklassen eine Gesamtgenauigkeit zwischen 82 % und 86 % anhand verschiedener Klassifikatoren.

MAXWELL ET AL., 2015 erzielen eine Gesamtgenauigkeit von 86.6 % bei der objekt-basierten Klassifikation von fünf Landbedeckungsklassen.

SHI ET AL., 2017 erlangen eine Gesamtgenauigkeit zwischen 76.86 % und 99.36 % bei einer pixel-basierten *super-resolution* Klassifikation von sechs Landbedeckungsklassen und unterschiedlichen Klassifikationsszenarien.

WANG ET AL., 2018 erreichen bei der objekt-basierten Klassifikation von drei respektive sieben Landbedeckungsklassen eine Gesamtgenauigkeit von 97.9 % respektive 79.3 %.

BUCK ET AL., 2015 erreichen bei der objekt-basierten Klassifikation von sechs Landbedeckungsklassen anhand verschiedener Klassifikatoren Gesamtgenauigkeiten zwischen 83.7 % und 87.9 %.

Im Bereich der Feldfruchtkartierung erreichen SCHULTZ ET AL., 2015 respektive IMMITZER ET AL., 2016 für die objekt-basierte Kartierung von fünf respektive sieben Klassen eine Gesamtgenauigkeit von 79.3 % und einen Kappa-Koeffizienten von 0.68 respektive 76.8 % und 0.699.

Im Bereich der objekt-basierten Klassifikation von neun Landschaftselementen erzielen O'CONNELL ET AL., 2015 eine Gesamtgenauigkeit von 91.97 % und einen Kappa-Koeffizienten Wert von 0.9087.

Die 18 (Groitzsch) respektive 21 (Rostock) Detailklassen erzielen Gesamtgenauigkeiten zwischen 54.9 % (Übertragbarkeitsdatensatz Rostock mit einer relativen Häufigkeit von 0) und 86.1 % (Übertragbarkeitsdatensatz Groitzsch mit einer relativen Häufigkeit von 1) (Abbildung 84). Die Werte des Kappa-Koeffizienten liegen zwischen 0.511 (Übertragbarkeitsdatensatz Rostock mit einer relativen Häufigkeit von 0) und 0.833 (Übertragbarkeitsdatensatz Groitzsch mit einer relativen Häufigkeit von 1) (Abbildung 84). Der Vergleich mit Ergebnissen aus der Literatur ist schwierig, da es nur wenige Veröffentlichungen mit einer relativ großen Klassenanzahl gibt. Generell zeigt sich jedoch eine Abnahme der Gesamtgenauigkeit mit Zunahme der zu erfassenden Klassen (MA ET AL., 2017).

ZLINSZKY ET AL., 2014 erreichen bei der Kartierung von zehn Landbedeckungsklassen auf der Grundlage von LiDAR-Daten eine Gesamtgenauigkeit von 68 % und einen Wert für den Kappa-Koeffizienten von 0.64.

BARRETT ET AL., 2016 erlangen für 15 Landbedeckungsklassen und drei Untersuchungsgebiete Gesamtgenauigkeiten von 94.3 %, 93.2 % respektive 93.8 %.

Auf Basis von hyperspektralen Luftbildern klassifizieren HAEST ET AL., 2017 zwischen sechs und 24 Landbedeckungsklassen und erzielen Gesamtgenauigkeiten und Werte für den Kappa-Koeffizienten von 93.82 % / 0.93 (6 Klassen), 91.68 % / 0.91 (11 Klassen), 88.17 % / 0.87 (17 Klassen) respektive 81.77 % / 0.8 (24 Klassen).

ZHU ET AL., 2012 erreichen bei der synergistischen Klassifikation von 17 Landbedeckungsklassen Gesamtgenauigkeiten zwischen 30.99 % (Verwendung ausschließlich der SAR-Daten) und 93.82 % (Verwendung des kompletten, synergistischen Datensatzes aus SAR-, optischen und Textur-Daten).

Generell zeigt sich, wie auch bei den Klassen der Hauptgruppe und Untergruppe, dass die erzielten Ergebnisse der Detailklassen im Bereich der in der Literatur gezeigten Werte liegen. Eine Ausnahme bildet der Übertragungsdatensatz Rostock mit niedrigen relativen Häufigkeiten. Hier werden niedrigere Genauigkeiten im Vergleich sowohl mit den anderen beiden Datensätzen als auch mit den Werten aus der Literatur erreicht. Eine mögliche Erklärung hierfür kann die reduzierte räumliche

Auflösung von 10 m beziehungsweise 20 m sein. MA ET AL., 2017 halten hierzu in ihrer Metastudie fest, dass mit steigender räumlicher Auflösung auch die erreichten Genauigkeiten zunehmen. Ein weiterer Grund kann die, im Vergleich zu den anderen beiden Datensätzen, größere zeitliche Differenz zwischen der Aufnahme der Referenzdaten und der Aufnahme der Satellitendaten sein.

Somit lässt sich für die Beantwortung der Forschungsfrage *Ist die Übertragung des Algorithmus auf andere Untersuchungsgebiete und andere Datengrundlagen möglich?* festhalten, dass durch die unabhängige Entwicklung der Methode auf dem Untersuchungsgebiet Rostock und die anschließende Übertragung des Algorithmus mit unveränderter Herangehensweise, beruhend auf der Merkmalsauswahl für die auf weichen Merkmalen basierenden Klassen sowie den Klassen basierend auf harten Merkmalen, auf die Übertragbarkeitsdatensätze mit zu erwartenden, geringen Schwankungen in den resultierenden Genauigkeiten (Kapitel 6.3), gezeigt wurde, dass der Algorithmus robust auf ein anderes Untersuchungsgebiet und eine andere Datengrundlage übertragbar ist. Die Forschungsfrage ist somit mit ja zu beantworten.

Eine Betrachtung der erzielten Ergebnisse auf Basis der einzelnen Klassen zeigt, dass bei den vier Klassen der Hauptgruppe sowohl innerhalb eines Untersuchungsgebietes beziehungsweise Datensatzes anhand der verschiedenen relativen Häufigkeiten als auch zwischen den Datensätzen keine große Streuung innerhalb der erzielten Genauigkeiten auftritt und somit ein homogenes Klassifikationsergebnis erzielt werden konnte.

Für fünf der sieben Klassen der Untergruppe gilt dies ebenso, allerdings weisen die Sumpf- und Moor-Klasse (W40) und die Klasse des Offenen Bodens (R00) eine größere Streuung innerhalb der erzielten Genauigkeiten sowie auch generell niedrigere Genauigkeiten im Vergleich zu den anderen Klassen auf. Da dies im ähnlichen Maße für alle drei betrachteten Datensätze auftritt wird von einem klassenspezifischen Problem ausgegangen. Gründe hierfür können eine unzureichende Klassenbeschreibung durch Trainingspunkte, eine klasseninterne Heterogenität vor allem in der Sumpf- und Moor-Klasse, ein deutlicher merkmalspezifischer Überlapp mit einer anderen Klasse und die daraus resultierenden niedrigen relativen Häufigkeiten im Bereich dieser Klassen oder die geringe Anzahl an Trainingspunkten (Abbildung 82) sein. Lösungsansätze sind eine Erweiterung der Anzahl an Trainingspunkten oder eine weitere Aufspaltung der Klassen um eine engere Definition im Sinne der Merkmalsausprägungen zu erlauben. Dies setzt ebenso eine Erweiterung der Anzahl an Trainingspunkten voraus. Die genauen Gründe sowie der geeignete Lösungsansatz müssen in weiteren Untersuchungen ermittelt werden.

Im Bereich der Detailklassen wird die Analyse der Ergebnisse getrennt nach Klassen basierend auf weichen Merkmalen beziehungsweise harten Merkmalen und dem Klassifikationsansatz durchgeführt. Auf harten Merkmalen sowie auf den BNTK-Objektgrenzen beruhen die Landschaftselement- und Walddetailklassen sowie die Siedlungs- und Infrastrukturdetailklassen. Ausschließlich auf harten Merkmalen beruhen die Gewässerdetailklassen. Die Grün- und Graslanddetailklassen beruhen auf weichen Merkmalen.

Im Bereich der Walddetailklassen (B11, B12, B13, B14, B15, B16) zeigen sich für den Entwicklungsdatensatz Rostock (Abbildung 43) und dem Übertragbarkeitsdatensatz Groitzsch (Abbildung 57) nur minimale Streuungen innerhalb der erzielten Genauigkeiten. Dies kann mit der Verwendung der BNTK-Polygone und der zeitlichen Nähe (sechs beziehungsweise vier Jahre) der Referenzdatensätze erklärt werden. Im Übertragbarkeitsdatensatz Rostock nimmt die Streuung innerhalb der erzielten Genauigkeit für die Walddetailklassen deutlich zu und die erzielten Genauigkeiten ab (Abbildung 71). Eine entscheidende Rolle kann hier die zeitliche Differenz zwischen Aufnahme der Referenzdaten (2003) und der Aufnahme der Satellitendaten (2017) und den damit einhergehenden Veränderungen spielen. Des Weiteren werden in den Referenzdatensätzen, entgegen der Definitionen, sowohl für Rostock als auch für Groitzsch, teils Polygone kleiner 2 ha als Waldobjekte und Polygone größer 2 ha als Landschaftselemente ausgewiesen. Dies führt bei der verwendeten



Klassendefinition zwangsläufig zu Fehlklassifikationen. Ausdruck findet dies auch in der, im Vergleich zu den Walddetailklassen, gesteigerten Streuung und verminderten erreichten Genauigkeit der Landschaftselementdetailklassen (B21, B23, B25, B26 und B27). Der Entwicklungsdatensatz Rostock erreicht, mit Ausnahme der Detailklasse Hecke (B26), die Ergebnisse mit der geringsten Streuung und den höchsten Genauigkeiten, während die Übertragbarkeitsdatensätze Groitzsch und Rostock generell eine höhere Streuung und geringere Genauigkeiten innerhalb der Landschaftselementdetailklassen aufweisen. Einflussnehmende Faktoren sind auch hier die BNTK-Polygone, die zeitliche Differenz zwischen den Datenerfassungen, aber auch die räumliche Auflösung der Satellitenszenen, welche mit 5 m beziehungsweise 10 m an die Grenzen der Sensibilität für sehr kleinräumige Klassen (z.B. Solitär (B25)) stößt.

Sowohl für die Siedlungs- und Infrastrukturdetailklassen (S10, S30, S50) als auch Gewässerdetailklassen (S14, S21, S31) konnten gute ( $> 0.7$  [F-Maß]) bis sehr gute ( $> 0.85$  [F-Maß]) Genauigkeiten bei einer geringen Streuung erreicht werden (Abbildung 43, Abbildung 57, Abbildung 71). Eine Ausnahme bildet die Klasse S50 im Übertragbarkeitsdatensatz Groitzsch. Hierbei wurden jedoch vor allem die Siedlungs- und Infrastrukturdetailklassen stark generalisiert. Die Literatur (VOLTERSEN ET AL., 2014) hat gezeigt, dass weitere Klassen möglich sind. Eine Integration kann in weiteren Untersuchungen geschehen.

Die auf weichen Merkmalen beruhenden Grün- und Graslanddetailklassen liefern, mit Ausnahme der Ruderal- und Staudenfluren (W40) im Übertragbarkeitsdatensatz Rostock, gute ( $> 0.7$  [F-Maß]) bis sehr gute ( $> 0.85$  [F-Maß]) Genauigkeiten bei einer geringen Streuung. Dies deutet auf generell stabile Grün- und Graslandflächen innerhalb der Untersuchungsgebiete hin. Die angedeutete Ausnahme der Ruderal- und Staudenfluren (W40) im Übertragbarkeitsdatensatz Rostock lässt sich zurückführen auf teils überflutet Flächen dieser Klasse und den damit verbundenen Fehlklassifikationen, vor allem im Bereich der Rostocker Heide.

Ein kritisch zu betrachtender Punkt innerhalb des Klassifikationsdesigns ist die Möglichkeit der Nicht-Zuweisung von Flächen innerhalb einer Klassifikationsebene. Der offensichtliche Nachteil ist hierbei, dass keine Informationen für diese Flächen abgeleitet werden. Der größte Vorteil dieses Vorgehens ist, dass Flächen, welche nicht eindeutig durch eine Klassendefinition erfasst werden, nicht falsch einer Klasse zugeordnet werden können. Ausdruck finden sowohl der genannte Vorteil als auch der genannte Nachteil durch die steigende Genauigkeit bei steigender relativen Häufigkeit und gleichzeitig sinkender klassifizierter Fläche. Betrachtet man die nicht klassifizierten Flächen fallen diese zu großen Teilen ( $> 70\%$ ) in die landwirtschaftlichen Flächen. Begründet liegt dies in der starken Veränderung dieser Flächen im Jahresverlauf von unbestandenen Flächen über einer heterogenen Vegetationsbedeckung (feldfruchtabhängig) hin zu unbestandenen Flächen. Durch die automatische Merkmalsauswahl können hierbei durch verschiedene Merkmale verschiedene Ausprägungen nicht nachvollziehbar gewählt werden. Dies führt dann zur Erfassung nicht aller Ausprägungen dieser Flächen. Weitere Untersuchungen müssen die Integration der unbestandenen und bestanden landwirtschaftlichen Flächen, getrennt nach Feldfruchtarten, prüfen und realisieren. Hierfür ist eine Erweiterung der Referenzdaten um Feldfruchtinformationen notwendig.

Die klassenweise Betrachtung der *Synergieeffekte* basierend auf den definierten Merkmalskategorien (Kapitel 6.4) hat gezeigt, dass in 10 der 16 Klassen die synergistische Verwendung aller Merkmalskategorien die höchsten Genauigkeiten erzeugt hat. In den verbleibenden sechs Klassen erreichte die Kombination der Merkmalskategorien der *multispektral-basierten Merkmale* (MS) und der *SAR-basierten Merkmale* (SAR) die höchste Genauigkeit. In keiner der 16 betrachteten Klassen konnte nur eine Merkmalskategorie höhere Genauigkeiten erreichen als bei der synergistischen Verwendung der Merkmalskategorien. Lediglich die Merkmalskategorien der *multispektral-basierten Merkmale* (MS) konnte für vier Klassen gleich hohe Genauigkeiten erzielen (Kapitel 6.4). Die darauf basierende Schlussfolgerung, dass durch die synergistische Verwendung von Fernerkundungsdaten die Klassifikationsgenauigkeit steigt kann durch weitere Studien untermauert werden (HYDE ET AL., 2006,

PETERS ET AL., 2011, SCHMIDT ET AL., 2017). Die Forschungsfrage *Verbessert die Synergie aus passiven und aktiven Fernerkundungsdaten die Klassifikationsgenauigkeit?* ist somit mit ja zu beantworten.

Eine Analyse der verwendeten Merkmalskategorien innerhalb der Klassifikation (Kapitel 6.1) zeigt, dass die *multispektral-basierten Merkmale* (MS) mit 85.1 % (Entwicklungsdatensatz Rostock), 89.7 % (Übertragbarkeitsdatensatz Groitzsch), 86.8 % (Übertragbarkeitsdatensatz Rostock) und 73.7 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale) klar dominieren. Die *geometrischen Merkmale* (GEO) sowie die *SAR-basierten Merkmale* (SAR) fallen mit 13.8 % respektive 1.1 % (Entwicklungsdatensatz Rostock), 7.3 % respektive 3 % (Übertragbarkeitsdatensatz Groitzsch), 2.6 % respektive 10.5 % (Übertragbarkeitsdatensatz Rostock) und 0 % respektive 9.6 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale) deutlich hinter den *multispektral-basierten Merkmalen* (MS) zurück. Innerhalb des Übertragbarkeitsdatensatz Rostock inklusive der multi-temporalen Merkmale gewinnen diese mit 16.7 % deutlich an Einfluss.

Eine weitere Unterteilung der Merkmalskategorien in ihre Merkmalsgruppen zeigt, dass bei den *multispektral-basierten Merkmalen* (MS) die Texturmerkmale mit 41.25 % (Entwicklungsdatensatz Rostock), 50.82 % (Übertragbarkeitsdatensatz Groitzsch), 40.4 % (Übertragbarkeitsdatensatz Rostock) respektive 34.52 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale) bis auf den Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale dominant sind. Innerhalb der *multispektral-basierten Merkmalen* (MS) des Übertragbarkeitsdatensatzes Rostock inklusive multi-temporaler Merkmale haben die spektralen Transformationen mit 36.9 % den größten Anteil. Diese Merkmalsgruppe befindet sich bei den anderen Datensätzen mit 33.75 % (Entwicklungsdatensatz Rostock), 19.67 % (Übertragbarkeitsdatensatz Groitzsch) und 29.29 % (Übertragbarkeitsdatensatz Rostock) an zweiter Stelle. Innerhalb der *multispektral-basierten Merkmalen* (MS) bilden die rein spektralen Merkmale mit 16.25 % (Entwicklungsdatensatz Rostock), 19.67 % (Übertragbarkeitsdatensatz Groitzsch), 18.18 % (Übertragbarkeitsdatensatz Rostock) respektive 16.67 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale) und die Vegetationsindices mit 8.75 % (Entwicklungsdatensatz Rostock), 9.83 % (Übertragbarkeitsdatensatz Groitzsch), 12.12 % (Übertragbarkeitsdatensatz Rostock) respektive 11.9 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale) den Abschluss. Die *SAR-basierten Merkmale* (SAR) unterteilen sich in Texturmerkmale und SAR-Rückstreuung verteilt auf 100 % respektive 0 % (Entwicklungsdatensatz Rostock), je 50 % (Übertragbarkeitsdatensatz Groitzsch), 58.33 % respektive 41.67 % (Übertragbarkeitsdatensatz Rostock) und 45.45 % respektive 54.55 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporaler Merkmale). Aus den gezeigten Ergebnissen kann geschlossen werden, dass die *multispektral-basierten Merkmalen* (MS) und innerhalb dieser die Texturmerkmale sowie die spektralen Transformationen die wichtigsten Merkmale für die Biotoptypenkartierung liefern. In der Literatur finden sich Beispiele, die dieses Ergebnis untermauern (BOCK ET AL., 2006, KIM & YEOM, 2014, LABA ET AL., 2010) aber auch diesem widersprechen (MAXWELL ET AL., 2015).

Ein kritisch zu betrachtender Punkt ist, dass eine unterschiedliche Anzahl an Merkmalen je Merkmalskategorien aus jeder Satellitenszene erzeugt werden kann. Bei den RapidEye-Daten werden für die *multispektral-basierten Merkmale* (MS) je Szene 68 Merkmale und damit 87.45 % (vier Szenen - Entwicklungsdatensatz Rostock) beziehungsweise 83.95 % (drei Szenen - Übertragbarkeitsdatensatz Groitzsch) aller möglichen Merkmale erzeugt. Bei den TerraSAR-X-Daten werden für die *SAR-basierten Merkmale* (SAR) je Szene 18 Merkmale und damit 5.78 % (eine Szene - Entwicklungsdatensatz Rostock) beziehungsweise 7.4 % (eine Szene - Übertragbarkeitsdatensatz Groitzsch) aller möglichen Merkmale erzeugt. Die *geometrischen Merkmale* (GEO) tragen, da sie nicht szenen-weise, sondern nur einmal je Untersuchungsgebiet erzeugt werden, mit 6.75 % (Entwicklungsdatensatz Rostock) beziehungsweise 8.64 % (eine Szenen - Übertragbarkeitsdatensatz Groitzsch) aller möglichen Merkmale, ebenfalls nur gering zu der Gesamtzahl der Merkmale bei. Bei den Sentinel-2-Daten werden für die *multispektral-basierten Merkmale* (MS) je Szene 152 Merkmale und damit 72.08 % (8 Szenen - Übertragbarkeitsdatensatz Rostock ohne multi-temporale Merkmale) beziehungsweise 67.44 % (8 Szenen -

Übertragbarkeitsdatensatz Rostock inklusive multi-temporalen Merkmale) aller möglichen Merkmale erzeugt. Bei den Sentinel-1-Daten werden für die *SAR-basierten Merkmale* (SAR) je Szene 18 Merkmale und damit 26.67 % (25 Szenen - Übertragbarkeitsdatensatz Rostock ohne multi-temporale Merkmale) beziehungsweise 24.95 % (25 Szenen - Übertragbarkeitsdatensatz Rostock inklusive multi-temporalen Merkmale) aller möglichen Merkmale erzeugt. Die *geometrischen Merkmale* (GEO) tragen, da sie nicht szenen-weise, sondern nur einmal je Untersuchungsgebiet erzeugt werden, mit 1.24 % (Übertragbarkeitsdatensatz Rostock ohne multi-temporale Merkmale) beziehungsweise 1.16 % (Übertragbarkeitsdatensatz Rostock inklusive multi-temporalen Merkmale) aller möglichen Merkmale, nur gering zu der Gesamtzahl der Merkmale bei. Beim Übertragbarkeitsdatensatz Rostock inklusive multi-temporalen Merkmale bilden diese 6.43 % der Gesamtanzahl an Merkmalen.

Die absolute Abweichung [%] des Anteils der tatsächlichen Anwendung findenden Merkmalskategorien (Abbildung 85) mit dem Anteil der Merkmalskategorie an der Gesamtmerkmalsanzahl [%] je Datensatz zeigt, dass mit Ausnahme des Entwicklungsdatensatzes Rostock die *multispektral-basierten Merkmale* (MS) stärker, die *geometrischen Merkmale* (GEO) etwa gleich beziehungsweise für den Entwicklungsdatensatz Rostock stärker, die *SAR-basierten Merkmale* (SAR) schwächer und die *multi-temporalen Merkmale* (MT) stärker in der Klassifikation vertreten sind. Dies zeigt, dass nicht der Anteil einer Merkmalskategorie an der Gesamtmerkmalsanzahl deren Gewicht innerhalb der Klassifikation definiert, sondern der Informationsgehalt innerhalb der Merkmalskategorie ausschlaggebend ist. Somit ist auch die letzte Forschungsfrage *Welche Merkmalskategorien spielen die größte Rolle bei der Klassifikation?* beantwortet.




Abbildung 85: Absolute Abweichung [%] der tatsächlichen Anwendung findenden Merkmalskategorien vom Anteil der Merkmalskategorie an der Gesamtmerkmalsanzahl [%] je Datensatz.

Ausblickend kann gesagt werden, dass die hauptsächlich gleichbleibenden, hohen erreichten Genauigkeiten zeigen, dass die entwickelte Methode innerhalb der Ökoregion sowie den verwendeten Daten gute bis sehr gute Ergebnisse erzielt und übertragbar ist, jedoch weitere Untersuchungen zeigen müssen, ob dies auch für weitere Ökoregionen und weitere Datenquellen gilt. Darüber hinaus gilt es zu evaluieren, ob die Trainingsdatenlage durch z.B. Citizen Science erweitert werden kann und die Klassentiefe durch spektral (z.B. ENMAP), räumlich (z.B. WorldView) oder zeitlich (z.B. Planet Doves) höher aufgelösten Fernerkundungsdaten erweitert werden kann. Auch der Fortschritt im Bereich der Datenanalyse (z.B. Neuronale Netzwerke) kann zu verbesserten Ergebnissen führen und muss bei weiterführenden Untersuchungen beachtet werden.

## 8 Literatur

- ABE, N. & KUDO, M., (2005): Entropy criterion for classifier-independent feature selection. *Lecture Notes in Computer Science*, 3684, 689-695.
- AGÜERA, F., AGUILAR, F. J. & AGUILAR, M. A. (2008): Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses. *ISPRS Journal of Photogrammetry & Remote Sensing*, 63, 635-646.
- AHMAD A. & DEY L. (2004): A feature selection technique for classificatory analysis. *Pattern Recognition Letters*, 26, 43-56.
- DE ALMEIDA FURTADO L. F., SILVA T. S. F. & DE MORAES NOVO E. M. L. (2013): Backscattering response of different land cover types in the Lago Grande de Curuai floodplain (Amazon, Brazil) determined from Radarsat-2 and TerraSAR-X data. *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, Foz do Iguaçu, PR, Brasil, 13. – 18. April 2013, INPE.
- ALBERTZ J. (2001): Grundlagen der Interpretation von Luft- und Satellitenbildern - Eine Einführung in die Fernerkundung. *Wissenschaftliche Buchgesellschaft*, Darmstadt, 204.
- AMARSAIKHAN, D., GANZORIG, M., ACHE, P. & BLOTEVOGEL, H. (2007): The integrated use of optical and InSAR data for urban land-cover mapping. *International Journal of Remote Sensing*, 28, 1161-1171.
- ASPINALL, R. J. (2002): Use of logistic regression for validation of maps of the spatial distribution of vegetation species derived from high spatial resolution hyperspectral remotely sensed data. *Ecological Modelling*, 157, 301-312.
- BAATZ, M. & SCHÄPE, A. (2000): Multiresolution segmentation — an optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T., Griesebner, G. (Eds.), *Angewandte Geographische Informationsverarbeitung*. Wichmann, Heidelberg, 12-23.
- BACHMANN, C. M., BETTENHAUSEN, M. H., FUSINA, R. A., DONATO, T. F., RUSS, A. L., BURKE, J. W., LAMELA, G. M., RHEA, W. J., TRUITT, B. R. & PORTER, J. H. (2003): A Credit Assignment Approach to Fusing Classifiers of Multiseason Hyperspectral Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 41, 2488-2499.
- BAN, Y. F., HU, H. T. & RANGEL, I. M. (2010): Fusion of Quickbird MS and RADARSAT SAR data for urban land-cover mapping: object-based and knowledge-based approach. *International Journal of Remote Sensing*, 31, 1391-1410.
- BALZER, S. (2000): Internationale Schutzgebietssysteme, insbesondere Natura 2000 als Bestandteil eines bundesweiten Vorrangflächenkonzepts. - In: Ssymank, A. (Bearb.): *Vorrangflächen, Schutzgebietssysteme und naturschutzfachliche Bewertung großer Räume in Deutschland*. (Schriftenreihe für Landschaftspflege und Naturschutz, 63), 147-168.
- BARGIEL, D. (2013): Capabilities of high resolution satellite radar for the detection of semi-natural habitat structures and grasslands in agricultural landscapes. *Ecological Informatics*, 13, 9-16.
- BAR MASSADA, A., KENT, R., BLANK, L., PEREVOLOTSKY, A., HADAR, L. & CARMEL, Y. (2012): Automated segmentation of vegetation structure units in a Mediterranean landscape. *International Journal of Remote Sensing*, 33, 346-364.
- BARRETT, B., NITZE, I., GREEN, S. & CAWKWELL, F. (2014): Assessment of multi-temporal, multi-sensor radar and ancillary spatial data for grasslands monitoring in Ireland using machine learning approaches. *Remote Sensing of Environment*, 152, 109-124.
- BARRETT, B., RAAB C., CAWKWELL F., GREEN S., NAGENDRA H. & HORNING N. (2016): Upland vegetation mapping using Random Forests with optical and radar satellite data. *Remote Sensing in Ecology and Conservation*, 2, 212-231.
- BECKETT, K., ROBERTSON, B. & STEYN, J. (2010): MTF Characterization and Deconvolution of RapidEye Imagery. *Proceedings of IGARSS 2010*, Honolulu, Hawaii.

- BENZ, U. C., HOFMANN, P., WILLHAUCK, G., LINGENFELDER, I., & HEYNEN, M. (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GISready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58, 239–258.
- BERBEROGLU, S., CURRAN, P., LLOYD, C. & ATKINSON, P. (2007): Texture classification of Mediterranean land cover. *International Journal of Applied Earth Observation and Geoinformation*, 9, 322–334.
- BERHANE, T.M., LANE, C.R., WU, Q., ANENKHONOV, O., CHEPINOGA, V., AUTREY, B.C., & LIU, H. (2018): Comparing pixel- and object-based approaches in effectively classifying wetland-dominated landscapes. *Remote Sensing*, 10, 46.
- BERRY, P.M., DAWSON, T.P., HARRISON, P.A. & PEARSON, R.G. (2002): Modeling potential impacts of climate change on the bioclimatic envelope of species in Britain and Ireland. *Global Ecology and Biogeography* 11, 6, 453–462.
- BEZDEK, J.C. (1981): Pattern Recognition with Fuzzy Objective Function Algorithms. Plenum Press, N. York.
- BHATTACHARYYA, A. (1943): On a measure of divergence between two statistical populations defined by their probability distributions. *Bulletin of the Calcutta Mathematical Society*, 35, 99–109.
- BLACKBURN G. A. & MILTON E. J. (1995): Seasonal variations in the spectral reflectance of deciduous tree canopies, *International Journal of Remote Sensing*, 16, 709–720.
- BLASCHKE, T. & STROBL, J. (2001): What's wrong with pixel? Some recent developments interfacing remote sensing and GIS. *Geo-Information-Systeme*, 14, 12–17.
- BLUM, A. L. & LANGLEY, P. (1997): Selection of relevant features and examples in machine learning. *Artificial Intelligence*, 245–271.
- BIRTH, G.S. & G. MCVEY (1968): Measuring the color of growing turf with a reflectance spectrophotometer. *Agronomy Journal*, 60, 640–643.
- BMU (2005): Deutsche Übersetzung durch BMU - Bewertung, Monitoring und Berichterstattung des Erhaltungszustands – Vorbereitung des Berichts nach Art. 17 der FFH-Richtlinie für den Zeitraum von 2001 –2007 (DocHab-04-03/03-rev.3). [http://www.umwelt.sachsen.de/umwelt/download/natur/Uebersetzung\\_BMU\\_HabDoc\\_040303\\_rev3.pdf](http://www.umwelt.sachsen.de/umwelt/download/natur/Uebersetzung_BMU_HabDoc_040303_rev3.pdf).
- BOCK, M. (2003): Remote sensing and GIS-based techniques for the classification and monitoring of biotopes Case examples for a wet grass- and moor land area in Northern Germany. *Journal for Nature Conservation*, 11, 145–155.
- BOCK, M., XOFIS, P., MITCHLEY, J., ROSSNER, G. & WISSEN, M. (2005): Object-oriented methods for habitat mapping at multiple scales – Case studies from Northern Germany and Wye Downs, UK. *Journal of Nature Conservation*, 13, 75–89.
- BOCHOW, M., SEGL, K. & KAUFMANN, H. (2007): An update system for urban biotope maps based on hyperspectral remote sensing data. *Proceedings 5th EARSeL Workshop on Imaging Spectroscopy. Bruges, Belgium, April 23–25*.
- BOGNER, C., SEO, B., ROHNER, D., & REINEKING, B. (2018): Classification of rare land cover types: Distinguishing annual and perennial crops in an agricultural catchment in South Korea. *PLOS ONE*, 13.
- BORENGASSER, M., HUNGATE W.S., & WATKINS, R. (2007): Hyperspectral Remote Sensing. *Principles and Applications*. CRC Press.
- BORK E. W. & SU G. J. (2007): Integrating LIDAR data and multispectral imagery for enhanced classification of rangeland vegetation: A meta analysis, *Remote Sensing of Environment*, 111, 11–24.
- BORG, L. (1977): Landscape analysis of Linköping region. Vegetation and land use. *Swedish Environmental Protection Agency-SNV PM 804*.
- BOSER B., GUYON, I. & VAPNIK V. N. (1992): A training algorithm for optimal margin classifiers. *Proceedings of 5th Annual Workshop on Computer Learning Theory, Pittsburgh, PA: ACM*, 144–152.
- BUCK, O., MILLÁN, V.E.G., KLINK, A. & PAKZAD, K (2015): Using information layers for mapping grassland habitat distribution at local to regional scales. *International Journal of Applied Earth Observation and Geoinformation*, 37, 83–89.

- BUDER, W., UHLEMANN, S. & KRÖBER, A. (2004): Biotoptypenliste für Sachsen: Materialien zu Naturschutz und Landschaftspflege. Sächsisches Landesamt für Umwelt und Geologie.
- BURGES, C. (1998): A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2, 121–167.
- BOURGEAU-CHAVEZ, L.L., RIORDAN, K., POWELL, R. B., MILLER, N. & NOWELS M. (2009): Improving Wetland Characterization with Multi-Sensor, Multi-Temporal SAR and Optical/Infrared Data Fusion, *Advances in Geoscience and Remote Sensing*, Gary Jedlovac (Ed.), ISBN: 978-953-307-005-6, InTech, DOI: 10.5772/8327.
- BREIMAN, L. (1996): Bagging predictors. *Machine Learning*, 24, 123–140.
- BREIMAN, L. (2001): Random Forest. *Machine Learning*, 45, 5–32.
- BRUZZONE, L., MARCONCINI, M., WEGMULLER, U. & WIESMANN, A. (2004): An advanced system for the automatic classification of multitemporal SAR images. *Ieee Transactions On Geoscience And Remote Sensing*, 42, 1321–1334.
- CAMPS-VALLS G. & BRUZZONE L. (2009): Kernel methods for Remote Sensing Data Analysis. Wiley & Sons.
- CASALS-CARRASCO, P., KUBO, S. & BABU MADHAVAN, B. (2000): Application of spectral mixture analysis for terrain evaluation studies. *International Journal of Remote Sensing*, 21, 3039–3055.
- CHANG, C.-C. & LIN, C.-J. (2013): LIBSVM: A Library for Support Vector Machines. <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>. (Zugriff: Mai 2015).
- CHERNOFF, H. (1952): A measure of asymptotic efficiency for tests of a hypothesis based on the sum of observations. *Annals of Mathematical Statistics*, 23, 493–507.
- CHI M., FENG R., & BRUZZONE L. (2008): Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem. *Advances in Space Research*, 41, 1793–1799.
- CHUST, G., DUCROT, D. & PRETUS, J. L. L. (2004): Land cover mapping with patch-derived landscape indices. *Landscape and Urban Planning*, 69, 437–449.
- CHUST, G., DUCROT, D. & PRETUS, J. L. L. (2004b): Land cover discrimination potential of radar multitemporal series and optical multispectral images in a Mediterranean cultural landscape. *International Journal of Remote Sensing*, 25, 3513–3528.
- CLARK, R. N., SWAYZE, G. A., WISE, R., LIVO, K. E., HOEFEN, T. M., KOKALY, R. F. & SUTLEY, S. J. (2007): USGS Digital Spectral Library splib06a, U.S. Geological Survey, Data Series 231.
- CLINTON, N., HOLT, A., SCARBOROUGH, J., YAN, L. & GONG, P. (2010): Accuracy assessment measures for object-based image segmentation goodness. *Photogrammetric Engineering & Remote Sensing*, 76, 289–299.
- COILLIE, F. M. V., VERBEKE, L. P. & WULF, R. R. D. (2007): Feature selection by genetic algorithms in object-based classification of IKONOS imagery for forest mapping in Flanders, Belgium. *Remote Sensing of Environment*, 110, 476–487.
- COHEN, J. (1960): A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20, 37–46.
- CONCHEDDA, G., DURIEUX, L. & MAYAUX, P. (2008): An object-based method for mapping and change analysis in mangrove ecosystems. *ISPRS Journal of Photogrammetry & Remote Sensing*, 63, 578–589.
- CONGALTON, R. G. & GREEN, K. (1992): The ABC's of GIS. *Journal of Forestry*, 90, 13–20.
- CONNER, R. W. & HARLOW, C. A. (1980): A Theoretical Comparison of Texture Algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2, 3.
- COUSINS, S. A. & IHSE, M. (1998): A methodological study for biotope and landscape mapping based on CIR aerial photographs. *Landscape and Urban Planning*, 41, 183–192.
- CUTLER, D.R., EDWARDS, T.C., JR., BEARD, K.H., CUTLER, A., HESS, K.T., GIBSON, J. & LAWLER, J.J. (2012): Random forests for classification in ecology. *Ecology*, 88, 2783–2792.
- CRISTIANINI N. & SHAW-TAYLOR J. (2000): An Introduction to Support Vector Machines and other Kernel-based Learning Methods. Cambridge, UK: Cambridge University Press.
- DAHL, F. (1908): Grundsätze und Grundbegriffe der biocoenotischen Forschung. *Zoologischer Anzeiger*, 33, 349–353.



- DALPONTE, M., BRUZZONE, L. & GIANELLE, D. (2008): Fusion of Hyperspectral and LIDAR Remote Sensing Data for Classification of Complex Forest Areas *IEEE Transactions on Geosciences and Remote Sensing*, 46, 1416-1427.
- DALPONTE, M., BRUZZONE L. & GIANELLE D. (2012): Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote sensing of environment*, 123, 258-270.
- DASH, M. & LIU, H. (1997): Feature selection for classification. *International Journal of Intelligent Data Analysis*, 1(3).
- DASH, M. & LIU, H. (1999): Handling large unsupervised data via dimensionality reduction. ACM SIGMOD Workshop on Research Issues in Data Mining and Knowledge Discovery.
- DASH, M., CHOI, K., SCHEUERMANN, P. & LIU, H. (2002): Feature Selection for Clustering – A Filter Solution. In: *Proceedings of the 2002 IEEE International Conference on Data Mining (ICDM'02)*, 115-122.
- DAVIS, C. E., MOSS, D. & HILL, M. O. (2004): EUNIS Habitat Classification Revised 2004. – Report to European Environment Agency, European Topic Center on Nature Protection and Biodiversity.
- DEAN, A. M. & SMITH, G. M. (2003): An evaluation of perparcel land cover mapping using maximum likelihood class probabilities. *International Journal of Remote Sensing*, 24, 2905-2920.
- DÍAZ-URIARTE R. & DE ANDRÉS S.A. (2006): Gene selection and classification of microarray data using random forest. *BMC Bioinformatics*, 7.
- DI GREGORIO A. & JANSEN, L. J. M. (2005): Land Cover Classification System (LCCS): Classification Concepts and User Manual for Software. Version 2. Technical Report 8. *FAO Environment and Natural Resources Service Series*, Rome.
- DLR (2002): Thomase Heege - Verfahren zur Anhebung des Signal/Rausch-Verhältnisses bei der Verarbeitung mehrkanaliger digitaler Datensätze. Patent DE10050331C2.
- DONG J., ZHUANG D., HUANG Y. & FU J. (2009): Advances in Multi-Sensor Data Fusion: Algorithms and Applications, *Sensors*, 9, 7771-7784.
- DRĂGUT, L., TIEDE, D. & LEVICK, S. R. (2010): ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*. 24:6, 859-871.
- DU, P., ZHANG, W., ZHANG, S. & XIA, J. (2009): Hyperspectral remote sensing image classification based on decision level fusion," *Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009*, 4, 940-943.
- DURO, D.C., FRANKLIN, S.E., & DUBÉ, M.G. (2012): A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, 118, 259-272.
- DURIC, N., PEHANI, P. & OSTIR, K., (2014): Application of in-segment multiple sampling in object-based classification. *Remote Sensing*, 6, 12138-12165.
- DUSSEUX, P., CORPETTI T., HUBERT-MOY L. & CORGNE S. (2014): Combined Use of multi-temporal optical and radar satellite images for grassland monitoring. *Remote Sensing*, 6, 6163-6182.
- DWD (2011): Klimadaten Deutschland - Zeitreihen an Stationen. Langjährige Mittelwerte an Stationen 1961-1990 bezogen auf Standort Rostock-Warnemünde.
- EASTWOOD, P.D., SOUISSI, S., ROGERS, S.I., COGGAN, R.A., BROWN, C.J., (2006): Mapping seabed assemblages using comparative top-down and bottom-up classification approaches. *Canadian Journal of Fisheries and Aquatic Sciences*, 63 (7), 1536-1548.
- EC (1995): CORINE Land Cover. Commission of the European Communities. <http://www.eea.europa.eu/publications/COR0-landcover>.
- EHLERS, M., GÄHLER, M. & JANOWSKY, R. (2003): Automated analysis of ultra high resolution remote sensing data for biotope type mapping: new possibilities and challenges. *ISPRS Journal of Photogrammetry & Remote Sensing*, 57, 315-326.
- EINER, M., FRITZ, T., MITTERMAYER, J., ROTH, A., BÖRNER, E. & BREIT, H. (2009): TerraSAR-X Ground Segment Basic Product Specification Document, TX-GS-DD-3302, v1.6, 18.03.2009. CAF Cluster Applied Remote Sensing, DLR, Germany.

- EISANK C., MIKE SMITH M. & HILLIER J. (2014): Assessment of multiresolution segmentation for delimiting drumlins in digital elevation models. *Geomorphology*, 214, 452–464.
- EL-MANZALAWY, Y. (2005): WLSVM. <http://perun.pmf.uns.ac.rs/radovanovic/dmsem/cd/install/LIBSVM/WLSVM/wlsvm.htm>. (Zugriff: Mai 2015).
- ENGDAHL, M. E. & HYPPA, J. M. (2003): Land-cover classification using multitemporal ERS-1/2 InSAR data. *IEEE Transactions On Geoscience And Remote Sensing*, 41, 1620–1628.
- Erikson, M. (2004): Species classification of individually segmented tree crowns in high-resolution aerial images using radiometric and morphologic image measures. *Remote Sensing of Environment*, 91, 467–477.
- ESA (2018A): Sentinel-1 User Guide. <https://earth.esa.int/web/sentinel/user-guides/sentinel-1-sar> (Stand: 8 Februar 2018).
- ESA (2018B): Sentinel-2 User Guide. <https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi> (Stand: 8 Februar 2018).
- ESA (2018C): Sentinel Application Platform (SNAP). <http://step.esa.int/main/toolboxes/snap/> (Stand: 19 Februar 2018).
- ESTES, L., OKIN, G., MWANGI, A. & SHUGART, H. (2008): Habitat selection by a rare forest antelope: A multi-scale approach combining field data and imagery from three sensors. *Remote Sensing of Environment*, 112, 2033–2050.
- EUNIS, 2014: About the European Nature Information System, EUNIS. <http://eunis.eea.europa.eu/> (Zugriff: Januar 2014).
- EURIMAGE (2010): Quickbird – Products & Services.
- EUROPÄISCHER RAT (2013): Richtlinie 92/43/EWG des Rates vom 21. Mai 1992 zur Erhaltung der natürlichen Lebensräume sowie der wildlebenden Tiere und Pflanzen. Konsolidierte Fassung vom 2013-07-01. <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=CONSLEG:1992L0043:20130701:DE:PDF>
- FERNÁNDEZ, N., PARUELO, J. M. & DELIBES, M. (2010): Ecosystem functioning of protected and altered Mediterranean environments: A remote sensing classification in Doñana, Spain. *Remote Sensing of Environment*, 114, 211–220.
- FEILHAUER, H., DAHLKE C., DOKTOR D., LAUSCH A., SCHMIDTLEIN S., SCHULZ G. & STENZEL S. (2014): Mapping the local variability of Natura 2000 habitats with remote sensing. *Applied Vegetation Science*, 17, 765–779.
- FOERSTER, M., FRICK, A., WALENTOWSLI, H. & KLEINSCHMIT, B. (2008): Approaches to utilizing Quickbird data for the monitoring of NATURA 2000 habitats. *Community Ecology*, 9, 155–168.
- FOODY, G.M. (1999): The continuum of classification fuzziness in thematic mapping. *Photogrammetric Engineering and Remote Sensing*, 65, 443–451.
- FOODY, G.M. (2002): Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80, 185–201.
- FOODY, G.M. & MATHUR, A. (2004): A relative evaluation of multiclass image classification by support vector machines. *IEEE Transaction of Geoscience and Remote Sensing*, 42, 1335–1343.
- FOODY, G.M. (2010): Assessing the accuracy of land cover change with imperfect ground reference data. *Remote Sensing of Environment*, 114, 2271–2285.
- FORMAN, R. T.T & M. GORDON (1986): Landscape Ecology. 620 S. - J. Wiley & Sons, New York.
- FRIETSCH, G. & SCHERFKE, M. (2014): CIR-Biotop- und Landnutzungskartierung im Freistaat Sachsen. Sächsisches Landesamt für Umwelt und Geologie. Abteilung Natur- und Landschaftsschutz. <http://www.umwelt.sachsen.de/umwelt/natur/18615.htm>
- FUREY, T., CRISTIANINI, N., DUFFY, N., BEDNARSKI, D.M. SCHUMMER & D. HAUSSLER (2000): Support vector machine classification and validation of cancer tissue samples using microarray expression data. *Bioinformatics*, 16, 906–914.
- GAMANYA, R., MAEYER, P. D. & DAPPER, M. D. (2007): An automated satellite image classification design using object-oriented segmentation algorithms: A move towards standardization. *Expert Systems with Applications*, 32, 616–624.

- GAO, Y., MAS J. F., MAATHUIS B. H. P., ZHANG X. & VAN DIJK, P. M. (2006): Comparison of pixel-based and objectoriented image classification approaches -a case study in a coal fire area, Wuda, Inner Mongolia, China. *International Journal of Remote Sensing*, 27, 4039-4055.
- GÄHLER, M. (2006): Biotoptypenerfassung auf Basis digitaler höchst auflösender Fernerkundungsdaten. *Institut für Geoinformatik und Fernerkundung an der Universität Osnabrück*.
- GALAL, A & HASAN H. (2012): Learning Flexible Hyperspectral Features. *International Journal of Remote Sensing Applications (IJRSA)*, 2, 44-48.
- GAMMA (2017): GAMMA Software. [https://www.gamma-rs.ch/uploads/media/GAMMA\\_Software\\_information\\_02.pdf](https://www.gamma-rs.ch/uploads/media/GAMMA_Software_information_02.pdf) (Stand: 19 Februar 2018).
- GARCIA M., RIANO D., CHUVIECO, E., SALAS, J. & DANSON, F. M. (2011): Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sensing of Environment*, 115, 1369-1379.
- GEERKEN, R. A. (2009): An algorithm to classify and monitor seasonal variations in vegetation phenologies and their inter-annual change. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64, 422-431.
- GERON, A. (2017): Hands-On Machine Learning with Scikit-Learn and TensorFlow. Concepts, Tools, and Techniques to Build Intelligent Systems. 568 S. - O'Reilly Media, Sebastopol.
- GHIMIRE B., ROGAN J. & MILLER J. (2010): Contextual land-cover classification: incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic. *Remote Sensing Letters*. 1, 45-54.
- GIMENEZ, M., JONG, R., DELLA R., KELLER, A. & SCHAEPMAN, M. (2017): Determination of grassland use intensity based on multi-temporal remote sensing data and ecological indicators. *Remote Sensing of Environment*. 198, 126-139.
- GITELSON, A. A., MERZLYAK M. N. & LICHTENTHALER H. K. (1996): Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. *Journal of Plant Physiology*, 148, 501-508.
- GOLUB, T. R., SLONIM, D. K., TAMAYO, P., HUARD, C., GAASENBEEK, M., MESIROV, J. P., COLLIER, H., LOH, M. H., DOWNING, J. R., CALIGIURI, M. A., BLOOMFIELD, C. D. & LANDER, E. S. (1999): Molecular Classification of Cancer: Class Discovery and Class Prediction by Gene Expression Monitoring. *Science*, 286, 531 – 536.
- GONG, P., MARCEAU, D. & P. J. HOWARTH (1992): A comparison of spatial feature extraction algorithms for land use classification with SPOT HRV data. *Remote Sensing of Environment*, 40, 137-151.
- GHOSH, A. & JOSHI, P.K. (2014): A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery. *International Journal of Applied Earth Observation*, 26, 298-311.
- GUO, B., DAMPER, R., GUNN, S. R. & NELSON, J. (2008): A fast separability-based feature-selection method for high-dimensional remotely sensed image classification. *Pattern Recognition*, 41, 1653-1662.
- GUYON, I., BOSER B. & VAPNIK, V. (1993): Automatic Capacity Tuning of Very Large VC-dimension Classifiers. *Advances in neural information processing*, 5, 147-155.
- GUYON I., WESTON J., BARNHILL, S. & VAPNIK, V. N. (2002): Gene selection for cancer classification using support vector machines. *Machine Learning*, 46, 389-422.
- GUYON, I. & ELISSEEFF, A. (2003): An Introduction to Variable and Feature Selection (Kernel Machines Section). *JMLR*, 3, 1157-1182.
- HAACK, B. & BECHDOL, M. (2000): Integrating multisensor data and RADAR texture measures for land cover mapping. *Computers & Geosciences*, 26, 411-421.
- HAACK, B. N. & KHATIWADA, G. (2010): Comparison and integration of optical and quadpolarization radar imagery for land cover/use delineation. *Journal of Applied Remote Sensing*, 4.
- HALL, M.A. & SMITH, L.A. (1998): Practical feature subset selection for machine learning. In: *Proceedings of the 21st Australian Computer Science Conference*, 181-191.
- HALL, M., FRANK E., HOLMES G., PFAHRINGER B., REUTEMANN P. & WITTEN I. H. (2009): The WEKA Data Mining Software: An Update, *SIGKDD Explorations*, Volume 11, Issue 1.

- HARALICK R. (1979):** Statistical and structural approaches to texture. In: *Proceedings of the IEEE*, 67, 786–804.
- HARALICK R., SHANMUGAM K., & DINSTEIN I. (1973):** Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3, 610–620.
- HAEST, B., VANDEN BORRE J., SPANHOVE T., THOONEN G., DELALIEUX S., KOOISTRA L., MÜCHER C. A., PAELINCKX D., SCHEUNDERS P. & KEMPENEERS P. (2017):** Habitat mapping and quality assessment of NATURA 2000 heathland using airborne imaging spectroscopy. *Remote Sensing*, 9, 266.
- HENDERSON F. M. & ANTHONY J. L. (1998):** Manual of Remote Sensing, Volume 2, Principles and Applications of Imaging Radar, 3rd Edition.
- HILDEBRANDT, G. (1996):** Fernerkundung und Luftbildmessung für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie. Heidelberg. 676.
- HILL, R. A. & A. G. THOMSON (2005):** Mapping woodland species composition and structure using airborne spectral and LiDAR data. *International Journal of Remote Sensing*, 17, 3763–3779.
- HILL, M. J., TICEHURST, C. J., LEE, J. S., GRUNES, M. R., DONALD, G. E. & HENRY, D. (2005):** Integration of optical and radar classifications for mapping pasture type in western Australia. *Ieee Transactions On Geoscience And Remote Sensing*, 43, 1665–1681.
- HOFFMANN, A., VAN DER VEGT, J.W. & LEHMANN, F. (2000):** Towards automated map updating: is it feasible with new digital data acquisition and processing techniques? *International Archives of Photogrammetry and Remote Sensing*, 33, 295–302.
- HOLTE, R.C. (1993):** Very simple classification rules perform well on most commonly used datasets. *Machine Learning*, 11, 63–91.
- HONG, S.K., SONG, I.J., BYUN, B.S., YOO, S. & NAKAGOSHI, N. (2005):** Application of biotope mapping for spatial environmental planning and policy: case studies in urban ecosystems in Korea. *Landscape Ecological and Engineering*, 1, 101–112.
- HONG, S.-H., KIM H.-O., WDOWINSKI S. & E. FELICIANO (2015):** Evaluation of polarimetric SAR decomposition for classifying wetland vegetation types. *Remote Sensing*, 7, 8563–8585.
- HORVAT, D., ŽALIK, B., & MONGUS, D. (2016):** Context-dependent detection of non-linearly distributed points for vegetation classification in airborne LiDAR. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 1–14.
- HUANG C., L. S. DAVIS, & J. R. G. TOWNSHEND (2002):** An assesement of support vector machines for land cover classifiocation. *International Journal of Remote sensing*, 23, 725–749.
- HUANG, S., POTTER, C., CRABTREE, R. L., HAGER, S. & GROSS, P. (2010):** Fusing optical and radar data to estimate sagebrush, herbaceous, and bare ground cover in Yellowstone. *Remote Sensing of Environment*, 114, 251–264.
- HUETE A. (1988):** A soil adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25, 295–309.
- HUETE, A., JUSTICE C. & LIU H. (1994):** Development of vegetation and soil indices for MODIS-EOS. *Remote Sensing of Environment*, 49, 224–234.
- HUETE, A., DIDAN, K., MIURA, T., RODRIGUEZ, E. P., GAO, X., AND FERREIRA, L. G. (2002):** Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83, 195–213.
- HUFKENS K., THOONEN G., BORRE J. V., SCHEUNDERS P. & CEULEMANS R. (2010):** Habitat reporting of a heathland site: Classification probabilities as additional information, a case study, *Ecological Informatics*, 5, 248–255.
- HUGHES G. F. (1968):** On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14, 55–63.
- HYDE, P., DUBAYAH, R., WALKER, W., BLAIR, J. B., HOFTON, M. & HUNSAKER, C. (2006):** Mapping forest structure for wildlife habitat analysis using multi-sensor (LiDAR, SAR/InSAR, ETM+, Quickbird) synergy. *Remote Sensing of Environment*, 102, 63–73.
- IHSE, M. (1978):** Aerial photo interpretation of vegetation in south and middle Sweden-a methodological study of medium scale mapping. *Statens Naturva Êrdsverk*, Stockholm, PM 1083.

- IMMITZER, M., ATZBERGER, C. & KOUKAL, T. (2012): Tree species classification with Random Forest using very high spatial resolution 8-band WorldView-2 satellite data. *Remote Sensing*, 4, 2661–2693.
- IMMITZER M., VUOLO F. & ATZBERGER C. (2016): First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. *Remote Sensing*, 8, 166.
- JENSEN, J. (2004): Introductory Digital Image Processing. A Remote Sensing Perspective. Upper saddle River N.J., 3<sup>rd</sup> Edition. Prentice-Hall.
- JENSEN J.R. (2007): Remote sensing of the environment: an earth resource perspective. 2, Prentice Hall series in geographic information science, Pearson Prentice Hall, Upper Saddle River, NJ, 592 p.
- JNCC (2010): Handbook for Phase 1 habitat survey - a technique for environmental audit. *England Field Unit Nature Conservancy Council*.
- JOHN, G. H., KOHAVI, R. & PFLEGER, K. (1994): Irrelevant features and the subset selection problem. In: *Proc. the Eleventh International Conference on Machine Learning*, 121-129.
- JUNG-ROTHENHÄUSLER F., H. WEICHELT & M. PACH (2007): RapidEye – A novel approach to space borne geo-information solutions. *ISPRS Hanover Workshop 2007: High-Resolution Earth Imaging for Geospatial Information*.
- KARATHANASSI, V., KOLOKOUSIS, P. & IOANNIDOU, S. (2007): A comparison study on fusion methods using evaluation indicators. *International Journal of Remote Sensing*, 28, 2309-2341.
- KAREGOWDA, A. G., MANJUNATH, A. S. & JAYARAM, M.A. (2010): Comparative study of attribute selection using gain ratio and correlation based feature selection. *International Journal of Information Technology and Knowledge Management*, 2, 271-277.
- KASZTA, Ž., VAN DE KERCHOVE, R., RAMOELO, A., CHO, M.A., MADONSELA, S., MATHIEU, R. & WOLFF, E. (2016): Seasonal Separation of African Savanna Components Using Worldview-2 Imagery: A Comparison of Pixel- and Object-Based Approaches and Selected Classification Algorithms. *Remote Sensing*, 8, 763.
- KE, Y., QUACKENBUSH, L. J. & IM, J. (2010): Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification. *Remote Sensing of Environment*, 114, 1141-1154.
- KEIL, M., BOCK, M., ESCH, T., METZ, A., NIELAND, S., PFITZNER, A. (2010): CORINE Land Cover Aktualisierung 2006 für Deutschland. *Abschlussbericht zu den F+E Vorhaben UBA FKZ 3707 12 200 und FKZ 3708 12 200*, Deutsches Zentrum für Luft- und Raumfahrt e.V., Deutsches Fernerkundungsdatenzentrum Oberpfaffenhofen, Januar 2010.
- KELLER, D.R. & GOLLEY, F.B., (2000): The Philosophy of Ecology: From Science to Synthesis. University of Georgia Press, Athens, GA, 114 pp.
- KIM, H. O. (2007): Beitrag sehr hochauflösender Satellitenfernerkundungsdaten zur Aktualisierung der Biotop- und Nutzungstypenkartierung in Stadtgebieten – Dargestellt am Beispiel von Seoul –. *Fakultät VI – Planen Bauen Umwelt der Technischen Universität Berlin*.
- KIM, H.O. & YEOM, J.M., (2014): Effect of red-edge and texture features for object-based paddy rice crop classification using RapidEye multi-spectral satellite image data. *International Journal of Remote Sensing*, 35, 7046–7068.
- KIM, S., MCGAUGHEY, R. J., ANDERSEN, H.-E. & SCHREUDER, G. (2009): Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. *Remote Sensing of Environment*, 113, 1575–1586.
- KIRA K. & RENDELL L. A. (1992): A Practical Approach to Feature Selection. In: *Ninth International Workshop on Machine Learning*, 249-256.
- KODANI E., AWAYA Y., TANAKA K. & MATSUMARA N. (2002): Seasonal patterns of canopy structure, biochemistry and spectral reflectance in a broad-leaved deciduous *Fagus crenata* canopy. *Forest Ecology and Management*, 167, 233–249.
- KOHAVI, R. & JOHN, G. H. (1997): Wrappers for Feature Subset Selection. *Artificial Intelligence*, 97, 273-324.
- KOLLER, D. & SAHAMI, M. (1996): Toward optimal feature selection. In: *Proceedings of International Conference on Machine Learning*.

- KONONENKO I. (1994): Estimating Attributes: Analysis and Extensions of RELIEF. In: *European Conference on Machine Learning*, 171-182.
- KULLBACK S. & LEIBLER R. A. (1951): On information and sufficiency. *Annals of Mathematical Statistics*, 22, 79–86.
- KUPLICH, T. M., FREITAS, C. C. & SOARES, J. V. (2000): The study of ERS-1 SAR and Landsat TM synergism for land use classification. *International Journal of Remote Sensing*, 21, 2101-2111.
- KURTZ C., PASSAT N., GANC P. & PUISSANT A. (2012): Extraction of complex patterns from multiresolution remote sensing images: A hierarchical top-down methodology. *Pattern Recognition*, 45, 685–706.
- KURVONEN, L. & HALLIKAINEN, M. T. (1999): Textural information of multitemporal ERS-1 and JERS-1 SAR images with applications to land and forest type classification in boreal zone. *IEEE Transactions on Geoscience And Remote Sensing*, 37, 680-689.
- KÜBLER, K. & AMMER, U. (1992): Der Einsatz von Fernerkundungsverfahren zur automatisierten Klassifizierung von Biotoptypen. In: *Natur und Landschaft*, 67 (2), 51-55.
- LABA, M., BLAIR, B., DOWNS, R., MONGER, B., PHILPOT, W., SMITH, S., SULLIVAN, P. & BAVEYE, P. C. (2010): Use of textural measurements to map invasive wetland plants in the Hudson River National Estuarine Research Reserve with IKONOS satellite imagery. *Remote Sensing of Environment*, 114, 876-886.
- LECKIE, D. G., GOUGEON, F. A., WALSWORTH, N., & PARADINE, D. (2003): Stand delineation and composition estimation using semi-automated individual tree crown analysis. *Remote Sensing of Environment*, 85, 355–369.
- LESER, H. (1997): Landschaftsökologie. Ansatz, Modelle, Methodik, Anwendung. Stuttgart.
- LESER, C. (2003): Entwicklung operationell einsatzfähiger Methoden zur Biotoptypen-Kartierung anhand hochauflösender HRSC-Daten. *Technischen Universität Berlin*.
- LEUVEN, R. S. E. W., GERIG, Y., POUDÉVIGNE, I., GEERLING, G. W., KOOISTRA, L., & AARTS, B. G. W. (2002): Cumulative impact assessment of ecological rehabilitation and infrastructure facilities in floodplains along the middle reach of the River Waal. In R. S. E. W. Leuven, I. Poudevigne, & R. M. Teeuw (Eds.), *Application of Geographic Information systems and remote sensing in river studies*. Leiden: Backhuys Publishers.
- LFULG (1994): Beschreibung der Kartiereinheiten und Luftbildinterpretationsschlüssel Freistaat Sachsen - Biotoptypen- und Landnutzungskartierung aus Colorinfrarot-Luftbildern - Sächsisches Landesamt für Umwelt und Geologie (LfULG).
- LFULG (2010): Beschreibung der Kartiereinheiten zur Neufassung der BTLNK – Sächsisches Landesamt für Umwelt, Landwirtschaft und Geologie (LfULG).
- LfUG (2003): Biotopkartierung in Sachsen - Kartieranleitung. Sächsisches Landesamt für Umwelt und Geologie.
- LILLESAND, T. & KIEFER, R. (2008): Remote Sensing and Image Interpretation. New York, John Wiley and Sons.
- LI, X., CHENG, X., CHEN, W., CHEN, G. & LIU, S. (2015): Identification of forested landslides using LiDAR data, object-based image analysis, and machine learning algorithms. *Remote Sensing*, 7, 9705–9726.
- LI, M., MA, L., BLASCHKE, T., CHENG, L. & TIEDE, D., (2016): A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. *International Journal of Applied Earth Observation and Geoinformation*, 49, 87–98.
- LIU, H. & SETIONO, R. (1995): Chi2: Feature selection and discretization of numeric Attributes. In: *Proc. IEEE 7th International Conference on Tools with artificial Intelligence*, 338-391.
- LIU, H. LI, J. & WONG, L. (2002): A comparative study on feature selection and classification methods using gene expression profiles and proteomic pattern. *Genomic Informatics*, 13, 51-60.
- LIU, H. & YU, L. (2005): Toward Integrating Feature Selection Algorithms for Classification and Clustering. *IEEE Transactions on Knowledge and Data Engineering*, 17, 4, 491-502.
- LIU, X., KRISHNAN A. & MONDRY A. (2005): An Entropy-based gene selection method for cancer classification using microarray data. *BMC Bioinformatics*, 6.



- LIU, Y. (2004): A comparative study on feature selection methods for drug discovery. *Journal of Chemical Information and Computer Sciences*, 44, 1823-1828.
- LIU, Y., BIAN, L., MENG, Y.H., WANG, H.P., ZHANG, S.F., YANG, Y.N., SHAO, X. M. & WANG, B. (2012): Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68, 144-156.
- LU, X., GUO, Q., LI, W., & FLANAGAN, J. (2014): A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94, 1-12.
- LUCIEER, A. & STEIN, A. (2002): Existential uncertainty of spatial objects segmented from satellite sensor imagery. *IEEE Transactions on. Geoscience and Remote Sensing*, 40, 2518-2521.
- LÖFVENHAFT, K., BJÖRN, C. & IHSE, M. (2002): Biotope patterns in urban areas: a conceptual model integrating biodiversity issues in spatial planning. *Landscape and Urban Planning*, 58, 223-240.
- LOWE B. & KULKARNI A. D. (2015): Multispectral Image Analysis Using Random Forest, *International Journal on Soft Computing*, 6, 1-14.
- LÖW, F., CONRAD, C. & MICHEL, U. (2015): Decision fusion and non-parametric classifiers for land use mapping using multi-temporal RapidEye data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108, 191-204.
- LUCAS, R., ROWLANDS, A., BROWN, A., KEYWORTH, S. & BUNTING, P. (2007): Rule-based classification of multi-temporal satellite imagery for habitat and agricultural land cover mapping. *ISPRS Journal of Photogrammetry & Remote Sensing*, 62, 165-185.
- LUCAS, R., BUNTING, P., PATERSON, M. & CHISHOLM, L. (2008): Classification of Australian forest communities using aerial photography, CASI and HyMap data. *Remote Sensing of Environment*, 112, 2088-2103.
- LUCAS, R., MEDCALF, K., BROWN, A., BUNTING, P., BREYER, J., CLEWLEY, D., KEYWORTH, S. & BLACKMORE, P. (2011): Updating the Phase 1 habitat map of Wales, UK, using satellite sensor data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 81-102.
- LUCAS R., BLONDA P., BUNTING P., JONES G., INGLADA J., ARIAS M., KOSMIDOU V., PETROU Z., MANAKOS I., ADAMO M., CHARNOCK R., TARANTINO C., MÜCHER C. A., JONGMAN R., KRAMER H., ARVOR D., HONRADO J. P. & MAIROTA P. (2015): The Earth Observation Data for Habitat Monitoring (EODHAM) System. *International Journal of Applied Earth Observation and Geoinformation*. 37, 17-28.
- LUNG (1998): Anleitung für die Kartierung von Biotoptypen in Mecklenburg-Vorpommern. – Materialien zur Umwelt, Heft 1/1998.
- LUNG (2010): Anleitung für die Kartierung von Biotoptypen und FFH-Lebensraumtypen in Mecklenburg-Vorpommern, 2. vollst. überarb. Aufl. – Materialien zur Umwelt, Heft 2/2010. *Landesamt für Umwelt und Natur Mecklenburg-Vorpommern*.
- MA, L., LI, M., BLASCHKE, T., MA, X., TIEDE, D., CHENG, L., CHEN Z., CHEN, D. (2016): Object-Based Change Detection in Urban Areas: The Effects of Segmentation Strategy, Scale, and Feature Space on Unsupervised Methods. *Remote Sensing*, 8, 761.
- MA L., LI, M., MAC, X., CHENG, L., DUA, P. & LIU, Y. (2017): A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*. 130, 277-293.
- MACK B., ROSCHER, R., STENZEL, S., FEILHAUER, H., SCHMIDTLEIN, S. & WASKE, B. (2016): Mapping raised bogs with an iterative one-class classification approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 120, 53-64.
- MAGHSOUDI, Y., COLLINS, M. & LECKIE, D. (2013): Radarsat-2 Polarimetric SAR Data for Boreal Forest Classification Using SVM and a Wrapper Feature Selector. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6, 1531-1538.
- MANSUROGLU, S., ORTACESME, V. & KARAGUZEL, O. (2006): Biotope mapping in an urban environment and its implications for urban management in Turkey. *Journal of Environmental Management*, 81, 175-187.

- MAO, Y., ZHOU, X., PI, D., SUN, Y. & WONG, S. T. C. (2005): Multiclass Cancer Classification by Using Fuzzy Support Vector Machine and Binary Decision Tree with Gene Selection. *Journal of Biomed Biotechnology*, 2, 160–171.
- MASSONET, D. & SOUYRIS, J.-C. (2008): Imaging with Synthetic Aperture Radar. 1. Auflage, EPFL Press.
- MATUSITA, K. (1955): Decision rules based on distance for problems of fit, two samples and estimation. *Annals of Mathematical Statistics*, 26, 631–641.
- MAXWELL, A.E., WARNER, T.A., STRAGER, M.P., CONLEY, J.F. & SHARP, A.L., (2015): Assessing machine-learning algorithms and image-and lidar-derived variables for GEOBIA classification of mining and mine reclamation. *International Journal of Remote Sensing*, 36, 954–978.
- MCNAIRN, H. & BRISCO, B. (2004): The application of C-band polarimetric SAR for agriculture: a review. *Canadian Journal of Remote Sensing*, 30, 525–542.
- MCNAIRN, H., CHAMPAGNE, C., SHANG, J., HOLMSTROM, D. & REICHERT, G. (2009): Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64, 434–449.
- MEDDENS, A., HICKE, J., VIERLING, L. & HUDAK, A. T. (2013): Evaluating methods to detect bark beetle-caused tree mortality using single-date and multi-date Landsat imagery. *Remote Sensing of Environment*, 132, 49–58.
- MEHNER, H., CUTLER, M., FAIRBAIRN, D. & THOMPSON, G. (2004): Remote sensing of upland vegetation: the potential of high spatial resolution satellite sensors. *Global Ecology and Biogeography*, 13, 359–369.
- MELGANI F. & BRUZZONE, L. (2004): Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transaction of Geoscience and Remote Sensing*, 42, 1778–1790.
- MELLOR, A., HAYWOOD, A., STONE, C. & JONES, S. (2013): The performance of random forests in an operational setting for large area sclerophyll forest classification. *Remote Sensing*, 5, 2838–2856.
- MEINEL, G. & HENNERSDORF, J., (2002): Erhebungsmethoden, Programme und Nomenklaturen der Flächenbedeckung und –nutzung. *Photogrammetrie-Fernerkundung-Geoinformation*, 4, 271–286.
- MERCIER G. & LENNON M. (2003): Support vector machines for hyperspectral image classification with spectral-based kernels. *IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings*, 1, 288–290.
- MÖBIUS, K. (1877): Die Auster und die Austernwirtschaft.- 126 pp., (Wiegandt, Hempel & Parey) Berlin.
- MÜCHER C. A., ROUPIOZ L., KRAMER H., BOGERS M. M. B., JONGMAN R. H. G., LUCAS R. M., KOSMIDOU V., PETROU Z. I., MANAKOS I., PADOA-SCHIOPPA E., ADAMO M. & BLONDA. P. (2015): Synergy of Airborne LiDAR and Worldview-2 satellite imagery for land cover and habitat mapping: a BIOSOS-EODHAM case study for the Netherlands. *International Journal of Applied Earth Observation and Geoinformation*. 37, 48–55.
- NEHRING, S. & ALBRECHT, U. (2006): Biotop, Habitat, Mikrohabitat - Ein Diskussionsbeitrag zur Begriffsdefinition. *Lauterbornia*, 38, 75–84.
- NEUBERT, M., HEROLD, H. & MEINEL, G. (2008): Assessing image segmentation quality-concepts, methods and applications. In: Blaschke, T., Lang, S., Hay, G.J. (Eds.), *Object-Based Image Analysis. Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. Springer, Berlin Heidelberg, 769–784.
- NIROUMAND J., SAFDARINEZHAD A. R., SAHEBI M. R. & MOKHTARZADE M. (2012): A novel approach to super resolution mapping of multispectral imagery based on pixel swapping technique. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, I-7, XXII ISPRS Congress, Melbourne, Australia.
- NOVACK, T., ESCH, T., KUX, H. & STILLA, U. (2011): Machine learning comparison between WorldView-2 and QuickBird-2-simulated imagery regarding object-based urban land cover classification. *Remote Sensing*, 3, 2263–2282.
- NOVAKOVIC, J., STRBAC, P. & BULATOVIĆ, D. (2011): Toward Optimal Feature Selection Using Ranking Methods and Classification Algorithms. *The Yugoslav Journal of Operations Research*, 119–135.

- NUTZ, M (2010): *Habitatkartierung im hochalpinen Raum: Qualitative Analyse und Evaluierung des HABITALP Interpretation Keys und Anwendung auf sehr hoch auflösenden Satellitendaten*. VDM Verlag Dr. Müller.
- O'CONNELL, J., BRADTER, U. & BENTON, T.G. (2015): Wide-area mapping of small-scale features in agricultural landscapes using airborne remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 109, 165–177.
- OLEIRE-OLTMANN S. D', COENRADIE B. & KLEINSCHMIT B. (2011): An Object-Based Classification Approach for Mapping Migrant Housing in the Mega-Urban Area of the Pearl River Delta (China). *Remote Sensing*, 3, 1710–1723.
- OLENIN, S. & DUCROTOY, J.-P. (2006): The concept of biotope in marine ecology and coastal management. *Marine Pollution Bulletin*, 53, 20–29.
- OLSON, R.S., LA CAVA W., MUSTAHSAN Z., VARIK A. & MOORE J. H. (2017): Data-driven advice for applying machine learning to bioinformatics problems. arXiv:170805070.
- ONOJEGHUO, A. O. & BLACKBURN, G. A. (2011): Optimising the use of hyperspectral and LiDAR data for mapping reedbed habitats. *Remote Sensing of Environment*, 115, 2025–2034.
- OSM (2015): OpenStreetMap Daten. <http://www.openstreetmap.org/>. Stand: 09.03.2018. Letzter Zugriff: 09.03.2018.
- PASHER, J., KING, D. & LINDSAY, K. (2007): Modelling and mapping potential hooded warbler (*Wilsonia citrina*) habitat using remotely sensed imagery. *Remote Sensing of Environment*, 107, 471–483.
- PAL, M. & FOODY, G. M. (2010): Feature selection for classification of hyperspectral data by SVM, *IEEE Transactions on Geoscience and Remote Sensing*, 48, 2297–2307.
- PAL, M., & MATHER, P. M. (2004): Assessment of the effectiveness of support vector machines for hyperspectral data. *Future Generation Computer Systems*, 20, 1215–1225.
- PAL, M., & MATHER, P. M. (2006): Some issue in classification of DAIS hyperspectral data. *International Journal of Remote Sensing*, 27, 2895–2916.
- PEARSON, R.L. & MILLER L.D. (1972): Remote mapping of standing crop biomass for estimation of productivity of the shortgrass prairie, Pawnee National Grasslands, Colorado. *Proc. of the 8th International Symposium on Remote Sensing of Environment*, ERIM International, 1357–1381.
- PENG, H. C., LONG, F. H. & DING, C. (2005): Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27, 1226–1238.
- PETERS, W. (2004): FFH-Verträglichkeitsprüfung. - In: Köppel, J., Peters, W. & Wende, W.: *Eingriffsregelung, Umweltverträglichkeitsprüfung, FFH-Verträglichkeitsprüfung*. Stuttgart.
- PETERS J., VAN COILLIE F., WESTRA T. & DE WULF R. (2011): Synergy of very high resolution optical and radar data for object-based olive grove mapping. *International Journal of Geographical Information Science*, 25, 971–989.
- PHINN, S.R., ROELFSEMA, C.M. & MUMBY, P.J. (2012): Multi-scale, object-based image analysis for mapping geomorphic and ecological zones on coral reefs. *International Journal of Remote Sensing*, 33, 3768–3797.
- POHL, C. & J. L. VAN GENDEREN (1998): Review article. Multisensor image fusion in remote sensing: concepts, methods and applications. *International Journal of Remote Sensing*, 19, 823–854.
- PIERCE, L. E., BERGEN, K. M., DOBSON, M. C. & ULABY, F. T. (1998): Multitemporal Land-Cover Classification Using SIR-C/X-SAR Imagery. *Remote Sensing of Environment*, 64, 20–33.
- PIGNATTI, S., CAVALLI, R. M., CUOMO, V., FUSILLI, L., PASCUCCHI, S., POSCOLIERI, M. & SANTINI, F. (2009): Evaluating Hyperion capability for land cover mapping in a fragmented ecosystem: Pollino National Park, Italy. *Remote Sensing of Environment*, 113, 622–634.
- PINTY, B. & M. M. VERSTRAETE (1992): GEMI: A non-linear index to monitor global vegetation from satellites, *Vegetation*, 101, 15–20.
- POLYCHRONAKI A., SPINDLER N., SCHMIDT A., STOINSCHKE B., ZEBISCH M., RENNER K., SONNENSCHNEIN R. & NOTARNICOLA C. (2015): Integrating RapidEye and ancillary data to map alpine habitats in South Tyrol, Italy. *International Journal of Applied Earth Observation and Geoinformation*. 37, 65–71.

- POWERS, D. M. W. (2011): Evaluation: From precision, recall and F-measure to ROC, Informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2, 37-63.
- QI, Z., YEH, A. G.-O., LI, X., & LIN, Z. (2012): A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data, *REMOTE SENSING OF ENVIRONMENT*, 118, 21-39.
- QIAN, J., ZHOU, Q. & HOU, Q. (2007): Comparison of pixel-based and object-oriented classification methods for extracting built-up areas in aridzone. *ISPRS Journal of Photogrammetry & Remote Sensing*, 163-171.
- QIU, L., GAO, T., GUNNARSSON, A., HAMMER, M. & VON BOTHMER, R. (2010): A methodological study of biotope mapping in nature conservation. *Urban Forestry & Urban Greening* 9, 161-166.
- RAPIDEYE AG (2010): RapidEye Standard Image Product Specifications - Version 3.0 - May 2010.
- RASTIVEIS H. (2015): Decision level fusion of LIDAR data and aerial color imagery based on Bayesian theory for urban area classification. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W5. International Conference on Sensors & Models in Remote Sensing & Photogrammetry, 23–25 Nov. 2015, Kish Island, Iran.
- RÄSÄNEN, A., RUSANEN, A., KUITUNEN, M. & LENSU, A. (2013): What makes segmentation good? A case study in boreal forest habitat mapping. *International Journal of Remote Sensing*. 34:23, 8603-8627.
- REES W.G. (2001): Physical principles of remote sensing. 2nd ed., Cambridge University Press, Cambridge.
- REMY, D. (2011): Landschaftselemente der Auen pleistozäner Sandlandschaften Nordwestdeutschlands und ihre Wiederherstellung am Beispiel der Unteren Hase. *Bericht der Reinhold-Tüxen-Gesellschaft*, 23, 77-89. Hannover 2011.
- REYNOLDS, J., WESSON, K., DESBIEZ, A.L.J., OCHOA-QUINTERO, J.M. & LEIMGRUBER, P. (2016): Using Remote Sensing and Random Forest to Assess the Conservation Status of Critical Cerrado Habitats in Mato Grosso do Sul, Brazil. *Land*, 5, 12.
- RICHARDSON A.J. & WIEGAND C.L. (1977): Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*. 43, 1541–1552.
- RICHTER, R. (2014): Interner Projektbericht der EOMAP GmbH und Co. KG.
- ROBNIK-SIKONJA M. & KONONENKO I. (1997): An adaptation of Relief for attribute estimation in regression. In: *Fourteenth International Conference on Machine Learning*, 296-304.
- RODRIGUEZ-GALIANO, V.F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M. & RIGOL-SANCHEZ, J.P. (2012): An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104.
- RODWELL, J. S. (2006): National Vegetation Classification: Users' handbook. Joint Nature Conservation Committee, Peterborough.
- ROELFSEMA, C., PHINN, S., JUPITER, S. & COMLEY, J. (2013): Mapping coral reefs at reef to reef-system scales, 10s-1000skm2, using object-based image analysis. *International Journal of Remote Sensing*, 18, 6367–6388.
- ROKITNICKI-WOJCİK D., WIE A. & CHOW-FRASER P. (2011): Transferability of object-based rule sets for mapping coastal high marsh habitat among different regions in Georgian Bay, Canada. *Wetlands Ecology and Management*, 19, 223-236.
- RUIZ, L.A, FERNÁNDEZ-SARRIA, A., & RECIO, J.A. (2004): Texture feature extraction for classification of remote sensing data using wavelet decomposition: A comparative study. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35, 1109-1115.
- SACHTELEBEN, J. & M. BEHRENS (2010): Konzept zum Monitoring des Erhaltungszustandes von Lebensraumtypen und Arten der FFH-Richtlinie in Deutschland. - Ergebnisse des F+E-Vorhabens "Konzeptionelle Umsetzung der EU-Vorgaben zum FFH-Monitoring und Berichtspflichten in Deutschland". *BfN-Skripten*, 278.
- SARKER, L. R. & NICHOL, J. E. (2011): Improved forest biomass estimates using ALOS AVNIR-2 texture indices. *Remote Sensing of Environment*, 115, 968-977.
- SAUL, S. & PURKIS, S. (2015): Semi-Automated Object-Based Classification of Coral Reef Habitat using Discrete Choice Models. *Remote Sensing*, 7, 15894-15916.

- SCHMIDT J., FASSNACHT F. E., FÖRSTER M. & SCHMIDTLEIN, S. (2017): Synergetic use of Sentinel-1 and Sentinel-2 for assessments of heathland conservation status. *Remote Sensing in Ecology and Conservation*. 1-15.
- SCHMIDT, J., FASSNACHT F. E., LAUSCH A. & SCHMIDTLEIN S. (2017A): Assessing the functional signature of heathland landscapes via hyperspectral remote sensing. *Ecological Indicators*. 73, 505–512.
- SCHOWENGERDT R.A. (1997): Remote Sensing. Models and methods for image processing. 2nd, rev. and ext. ed., Academic Press, London.
- SCHULTZ, B., IMMITZER, M., FORMAGGIO, A., SANCHES, I., LUIZ, A. & ATZBERGER, C., (2015): Self-guided segmentation and classification of multi-temporal Landsat 8 images for crop type mapping in Southeastern Brazil. *Remote Sensing*. 7, 14482–14508.
- SCHUSTER, R., & BRAUNECKER, B. (2000): Calibration of the LH systems ADS40 airborne digital sensor. IAPRS - Vol. XXXIII. Amsterdam.
- SCHUSTER, C., SCHMIDT, T., CONRAD, C., KLEINSCHMIT, B. & FÖRSTER, M. (2015): Grassland habitat mapping by intra-annual time series analysis—Comparison of RapidEye and TerraSAR-X satellite data. *International Journal of Applied Earth Observation and Geoinformation*. 34, 25–34.
- SCIPY (2016): Ermitteln eines lokalen Maximums anhand von Python. <https://docs.scipy.org/doc/scipy-0.16.1/reference/generated/scipy.signal.argrelextrema.html>. Stand: 03.11.2016. Letzter Zugriff: 03.11.2016.
- SEGL, K., ROESSNER, S., HEIDEN, U., KAUFMANN, H., (2003): Fusion of spectral and shape features for identification of urban surface cover types using reflective and thermal hyperspectral data. *Journal of Photogrammetry and Remote Sensing*. 58, 99–112.
- SESNIE, S. E., GESSLER, P. E., FINEGAN, B. & THESSLER, S. (2008): Integrating Landsat TM and SRTM-DEM derived variables with decision trees for habitat classification and change detection in complex neotropical environments. *Remote Sensing of Environment*, 112, 2145-2159.
- SHAHSHAHANI B. M. & LANDGREBE D. A. (1994): The effect of unlabeled samples in reducing the small sample size problem and mitigating the Hughes phenomenon. *IEEE Transactions on Geoscience and Remote Sensing*, 32, 1087-1095.
- SIMONSON W. D., ALLEN H. D. & COOMES, D. A. (2013): Remotely sensed indicators of forest conservation status: Case study from a Natura 2000 site in southern Portugal. *Ecological Indicators*, 24, 636–647.
- STICKLER, C. M. & SOUTHWORTH, J. (2008): Application of multi-scale spatial and spectral analysis for predicting primate occurrence and habitat associations in Kibale National Park, Uganda. *Remote Sensing of Environment*, 112, 2170-2186.
- SKOWRONEK, S., ASNER, G.P. & FEILHAUER, H. (2017): Performance of one-class classifiers for invasive species mapping using airborne imaging spectroscopy. *Ecological Informatics*. 2017, 37, 66–76.
- STORY, M. & CONGALTON, R. G. (1986): Accuracy assessment: a user's perspective. *Photogrammetric Engineering and Remote Sensing*, 52, 397–399.
- STRAATSMA, M. & BAPTIST, M. (2008): Floodplain roughness parameterization using airborne laser scanning and spectral remote sensing. *Remote Sensing of Environment*, 112, 1062-1080.
- STRASSER, T. & LANG, S. (2015): Object-based class modelling for multi-scale riparian forest habitat mapping. *International Journal of Applied Earth Observations and Geoinformation*. 37, 29-37.
- STREIT, B. (1992): Umweltlexikon.- 384 S., (Herder) Freiburg.
- STUMPF, A. & KERLE, N. (2011): Object-oriented mapping of landslides using Random Forests. *Remote Sensing of Environment*. 115, 2564–2577.
- SRIPADA R.P, HEINIGER R.W., WHITE J.G. & MEIJER A. D. (2006): Aerial color infrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98, 968–977.
- SUKOPP, H. & WEILER, S. (1988): Biotope Mapping and Nature Conservation Strategies in Urban Areas of the Federal Republic of Germany. *Landscape and Urban Planning*, 15, 39-58.
- TADJUDIN S. & LANDGREBE D.A. (1999): Covariance estimation with limited training samples. *IEEE Transactions on Geoscience and Remote Sensing*, 37, 2113-2118.

- TAFT, O. W., HAIG, S. M. & KIILSGAARD, C. (2003): Use of Radar Remote Sensing (RADARSAT) to Map Winter Wetland Habitat for Shorebirds in an Agricultural Landscape. *Environmental Management*, 32, 268-281.
- TAN, F. (2007): Improving Feature Selection Techniques for Machine Learning. Dissertation, Georgia State University.
- TANSEY, K., CHAMBERS, I., ANSTEE, A., DENNISS, A. & LAMB, A. (2008): Object-oriented classification of very high resolution airborne imagery for the extraction of hedgerows and field margin cover in agricultural areas. *Applied Geography*, 29, 1-13.
- TANSLEY, A. G. (1935): The Use and Abuse of Vegetational Concepts and Terms. *Ecology*, 16, No. 3, 284-307.
- THEAU, J., PEDDLE, D. & DUGUAY, C. (2005): Mapping lichen in a caribou habitat of Northern Quebec, Canada, using an enhancement-classification method and spectral mixture analysis. *Remote Sensing of Environment*, 94, 232-243.
- THEODORIDIS S. & KOUTROUBAS K. (2009): Pattern Recognition, 4<sup>th</sup> Edition. Academic Press (2009).
- THORNTON, M. W., ATKINSON, P. M., & HOLLAND, D. A. (2006): Sub-pixel mapping of rural land cover objects from fine spatial resolution satellite sensor imagery using super-resolution pixel-swapping. *International Journal of Remote Sensing*, 27, 473-491.
- THORNTON, M. W., ATKINSON, P. M., & HOLLAND, D. A. (2007): A linearised pixel-swapping method for mapping rural linear land cover features from fine spatial resolution remotely sensed imagery. *Computers & Geosciences*, 32, 1261-1272.
- TISCHLER, W. (1955): Synökologie der Landtiere.- 414 pp., (Fischer) Stuttgart.
- TOBLER W. (1970): A computer movie simulating urban growth in the Detroit region. *Economic Geography*, 46, 234-240.
- TRIMBLE (2014): Trimble eCognition® Developer - Reference Book. <http://www.ecognition.com/free-trial>. Stand: 04.08.2018. Letzter Zugriff: 04.08.2018.
- TRODD, N.M. (1996): Analysis and representation of heathland vegetation from near-ground level remotely-sensed data. *Global Ecology and Biogeography Letters*, 5, 206-216.
- TUCKER, C.J. 1979: Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of the Environment*, 8, 127-150.
- TUOMINEN, S. & PEKKARINEN, A. (2005): Performance of different spectral and textural aerial photograph features in multi-source forest inventory. *Remote Sensing of Environment*, 94, 256-268.
- ULABY, F. T., KOUYATE F., BRISCO B. & WILLIAMS L. (1986): Textural Information in SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 24, 2, 235-245.
- ULABY, F.T., MOORE, R.K. & FUNG, A.K. (1986A): Microwave Remote Sensing, Active and Passive, vol. II, Artech House, Dedham.
- ULLMANN, T., SCHMITT A., ROTH A., DUFFE J., DECH S., HUBBERTEN H.-W. & BAUMHAUER R. (2014): Land cover characterization and classification of arctic tundra environments by means of polarized synthetic aperture X- and C-band radar (PolSAR) and landsat 8 multispectral imagery – Richards Island, Canada. *Remote Sensing*, 6, 8565-8593.
- UKBAP (2007): Report on the Species and Habitat Review - Report by the Biodiversity Reporting and Information Group (BRIG) to the UK Standing Committee.
- UKBAP (2010): UK Biodiversity Action Plan - Priority Habitat Descriptions - UK Biodiversity Action Plan, Priority Habitat Descriptions. BRIG (ed. Ant Maddock).
- VAHLE H.-CH. (1990): Grundlagen zum Schutz der Vegetation oligotropher Stillgewässer in Nordwestdeutschland. *Naturschutz und Landschaftspflege Niedersachsen*, 22.
- VAN DER SANDE, C., DE JONG, S. & DE ROO, A. (2003): A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. *International Journal of Applied Earth Observation and Geoinformation*, 4, 217-229.
- VAPNIK V. N. (1995): The Nature of Statistical Learning Theory. New York: Springer-Verlag.



- VARELA, R. A. D., REGO, P. R., IGLESIAS, S. C. & SOBRINO, C. M. (2008): Automatic habitat classification methods based on satellite images: A practical assessment in the NW Iberia coastal mountains. *Environmental Monitoring and Assessment*, 144, 229-250.
- VOLTERSEN, M., BERGER, C., HESE, S., & SCHMULLIUS, C. (2014): Object-based land cover mapping and comprehensive feature calculation for an automated derivation of urban structure types at block level. *Remote Sensing of Environment*, 154, 192-201.
- WAGNER, W., ULLRICH, A. & BRIESE, C., (2003): Der Laserstrahl und seine Interaktion mit der Erdoberfläche. *Österreichische Zeitschrift für Vermessung und Geoinformation*, Vol. 2003, No. 4, pp. 1-16.
- WALZ, U. (2004): Landschaftsstrukturmaße - Indizes, Begriffe und Methoden. – In: Walz, U., Lütze, G., Schultz, A. & Syrbe, R.-U.: *Landschaftsstruktur im Kontext von naturräumlicher Vorprägung und Nutzung - Datengrundlagen, Methoden und Anwendungen*. – IÖR-Schriften, 43: 15-27, Dresden (IÖR - Leibniz-Institut für ökologische Raumentwicklung Dresden).
- WALZ, U. (2013): *Landschaftsstrukturmaße und Indikatorensysteme zur Erfassung und Bewertung des Landschaftswandels und seiner Umweltauswirkungen – unter besonderer Berücksichtigung der biologischen Vielfalt*. *Habilitationsschrift*. Universität Rostock, Agrar- und Umweltwissenschaftliche Fakultät.
- WANG, Z. & BOVIC, A. C. (2002): A Universal Image Quality index. *IEEE Signal Processing Letters*, 9, 81-84.
- WANG, L., SOUSA, W. P., GONG, P. & BIGING, G. S. (2004): Comparison of IKONOS and QuickBird images for mapping mangrove species on the Caribbean coast of Panama. *Remote Sensing of Environment*, 91, 432-440.
- WANG, L., MARZAHN, P., BERNIER, M. & LUDWIG, R. (2018): Mapping permafrost landscape features using object-based image classification of multi-temporal SAR images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 141, 10-29.
- WASER, L. T., ECKER, K., GINZLER, C., KÜCHLER, M., SCHWARZ, M. & THEE, P. (2006): Extraction of forest parameters in a mire environment using airborne spectral data and digital surface models. *Workshop on 3D Remote Sensing in Forestry, 14th-15th Feb. 2006, Vienna*.
- WASKE, B. & VAN DER LINDEN, S. (2008): Classifying multilevel imagery from SAR and optical sensors by decision fusion. *Ieee Transactions On Geoscience And Remote Sensing*, 46, 1457-1466.
- WASKE, B. & BRAUN, M. (2009): Classifier ensembles for land cover mapping using multitemporal SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64, 450-457.
- WEDDING, L. M., FRIEDLANDER, A. M., MCGRANAGHAN, M., YOST, R. S. & MONACO, M. E. (2008): Using bathymetric lidar to define nearshore benthic habitat complexity: Implications for management of reef fish assemblages in Hawaii. *Remote Sensing of Environment*, 112, 4159-4165.
- WEIERS, S., BOCK, M., WISSEN, M. & ROSSNER, G. (2004): Mapping and indicator approaches for the assessment of habitats at different scales using remote sensing and GIS methods. *Landscape and Urban Planning*, 67, 43-65.
- WESTON, I. J., MUKHERJEE S., CHAPPELLE O., PONTIL M., POGGIO T. & VAPNIK V. (2000): Feature selection for SVMs. *Advances in Neural Information Processing Systems*, 13.
- WESTON, I. J., BARNHILL, S. & VAPNIK, V. (2002): Gene selection for cancer classification using Support Vector Machines. *Machine Learning*, 46, 389-422.
- WITTIG, R. & SCHREIBER, K.F. (1983): A quick method for assessing the importance of open spaces in towns for urban nature conservation. *Biological Conservation* 26, 54-64.
- YANG, L., ALBREGTSEN F., LØNNESTAD T. & GRØTTUM P. (1995): A supervised approach to the evaluation of image segmentation methods, *Proceedings of 6th International Conference: Computer Analysis of Images and Patterns*, 759-765.
- YAO, N., LIN, Z. & ZHANG, J. (2010): Feature selection based on mutual information and its application in hyperspectral image classification. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 6291 LNAI, 561-566.
- YILMAZ, B., GÜLEZ, S. & KAYA, L. G. (2010): Mapping of biotopes in urban areas: A case study of the city of Bartın and its environs, Turkey. *Scientific Research and Essays*, 5, 352-365.

- YU, Q., GONG, P., CLINTON, N., BIGING, G., KELLY, M. & SCHIROKAUER, D. (2006): Object-based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery. *Photogrammetric Engineering & Remote Sensing*, 72, 799-811.
- ZENG Y., ZHANG J., & VAN GENDEREN, J. L. (2006): Comparison and analysis of remote sensing data fusion techniques at feature and decision levels. In: *ISPRS 2006: ISPRS mid-term symposium 2006 remote sensing: from pixels to processes*, 8-11 May 2006, Enschede, the Netherlands. Enschede: ITC, 2006.
- ZEPP, H. & MÜLLER, M. (1999): Landschaftsökologische Erfassungsstandards – Ein Methodenbuch. (Forschungen zur deutschen Landeskunde, Bd. 244). Flensburg.
- ZHANG Q., XIAO X., BRASWELL B., LINDER E., OLLINGER S., SMITH M.-L., JENKINS J. P., BARET F., RICHARDSON A. D., MOORE B., MINOCH R. (2006): Characterization of seasonal variation of forest canopy in a temperate deciduous broadleaf forest, using daily MODIS data. *Remote Sensing of Environment*, 105, 189–203.
- ZHOU, Q., & ROBSON M. (2001): Automated rangeland vegetation cover and density estimation using ground digital images and a spectral-contextual classifier. *International Journal of Remote Sensing*, 22, 3457–3470.
- ZHU, Z., WOODCOCK, C. E., ROGAN, J. & KELLNDORFER J (2012): Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using Landsat and SAR data, *Remote Sensing of Environment*, 117, 72-82.
- ZLINSZKY, A., SCHROIFF, A., KANIA, A., DEÁK, B., MÜCKE, W., VÁRI, Á., SZÉKELY, B. & PFEIFER, N. (2014): Categorizing grassland vegetation with full-waveform airborne laser scanning: A feasibility study for detecting Natura 2000 Habitat Types. *Remote Sensing*, 6, 8056–8087.

## Anhang

Abbildung A 1: Vergleich von Referenzspektren für Wasser (oben), Kiefer (mitte) und Wiese (unten) mit den Grauwerten vor (rot, rechte Achse) und den Reflektanzen nach (blau, linke Achse) der Atmosphärenkorrektur dreier RapidEye-Aufnahmezeitpunkte des Testgebietes Rostock. ....	172
Abbildung A 2: F-Maß (y-Achse) je Merkmal (x-Achse) für die Klassen der Untergruppe.....	177
Abbildung A 3: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl (Unterklassen der Baumvegetation).....	178
Abbildung A 4: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern (Unterklassen der Baumvegetation). ....	178
Abbildung A 5: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl (Unterklassen des Grünlandes).....	179
Abbildung A 6: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern (Unterklassen des Grünlandes). ....	180
Abbildung A 7: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl (Unterklassen der Siedlung und Infrastruktur).....	181
Abbildung A 8: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern (Unterklassen der Siedlung und Infrastruktur). ....	181
 Tabelle A 1: BNTK-Codes der Biotoptypen- und Landnutzungsklassen für das Land Sachsen.....	173
Tabelle A 2: BLNTK-Codes der Biotoptypen- und Landnutzungsklassen für das Land Mecklenburg-Vorpommern.....	175
Tabelle A 3: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Entwicklungsgebiet Rostock.....	182
Tabelle A 4: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Übertragbarkeitsgebiet Groitzsch.....	184
Tabelle A 5: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Übertragbarkeitsgebiet Rostock.....	185
Tabelle A 6: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Übertragbarkeitsgebiet Rostock inklusiver multi-temporalen Merkmale. ....	188




Abbildung A 1: Vergleich von Referenzspektren für Wasser (oben), Kiefer (mitte) und Wiese (unten) mit den Grauwerten vor (rot, rechte Achse) und den Reflektanzen nach (blau, linke Achse) der Atmosphärenkorrektur dreier RapidEye-Aufnahmezeitpunkte des Testgebietes Rostock.

Tabelle A 1: BNTK-Codes der Biotoptypen- und Landnutzungsklassen für das Land Sachsen.

HG	UG	Bestand/Biotoptyp	Merkmale aus BNTK /Problem	VB
2 Gewässer	21 Fließgewässer	21200 Bach	überwachsen	-
		21400 Fluss	teilweise überwachsen	o
	23 Stillgewässer	23200 Ausdauerndes Kleingewässer (<1ha )	teilweise überwachsen	o
		23300 Teich (≥1ha)		+
		23600 Altwasser	überwachsen, nur an Form erkennbar	-
		23800 Restgewässer, Abbaugewässer	Tagebau	-
	24 gewässerbegleitende Vegetation	24500 gewässerbegleitende Gehölze	Auwald?	-
3 Moore, Sümpfe	31 Hochmoor, Zwischenmoor	-	nicht vorhanden	-
	32 Niedermoor, Sumpf		nicht vorhanden	-
4 Grünland, Ruderalflur	41 Wirtschaftsgrünland	41200 mesoph. Grünland, Fettwiesen und -weiden, Bergwiesen (extensiv)	Bestand/ Biotop nicht kartierbar via CIR	-
		41300 Intensivgrünland, artenarm	Bestand/ Biotop nicht kartierbar via CIR	-
	42 Ruderalflur, Staudenflur	42100 trocken-frisch	Bestand/ Biotop nicht kartierbar via CIR	-
5 Magerrasen, Felsfluren, Zwergstrauch- heiden	51 anstehender Fels		keine Untergruppen	-
	52 Blockschutthalden		keine Untergruppen	-
	53 größere Lesesteinhaufen und offene Steinrücken		keine Untergruppen	-
	54 offene Flächen	54200 sonstige offene Flächen		+
	55 Zwergstrauchheiden und Borstgrasrasen		nicht vorhanden	-
	56 Magerrasen trockender Standorte		Bestand/ Biotop nicht kartierbar via CIR	+
6 Baumgruppen, Hecken, Gebüsche	61 Feldgehölz/Baumgruppe	61300 Laubreinbestand	100 m <sup>2</sup> - 1 ha, Höhe nicht erkennbar, Trennung von Gebüsch nicht möglich	o
		61400 Laubmischbestand		o
	62 Baumreihe		nicht vorhanden	+
	63 Allee		nicht vorhanden	+
	64 Solitär, Baumgruppe		nicht vorhanden	+
	65 Hecke		nicht vorhanden	+
	66 Gebüsch	66300 Gebüsch frischer Standorte	Höhe nicht erkennbar, Trennung von Laub/Nadelbeständen nicht möglich	+
	67 Streuobstwiese		bei ausreichender Fläche und Anzahl von Bäumen erkennbar	-
	71 Laubwald	71500 Pappel		o

7 Wälder und Forsten		71900 sonstiger Laubholzreinbestand	nicht differenziert/nicht erkannt	o
	72 Nadelwald	72900 sonstiger Nadelholzreinbestand	nicht differenziert/nicht erkannt	o
	73 Laub-Nadel-Mischwald	731 Eiche + sonstige Nadel- / Laubreinbestand		-
	74 Nadel-Laub-Mischwald	742 Kiefer + sonstige Nadel- / Laubreinbestand		-
	75 Laubmischwald	754 Robinie + sonstige Nadel- / Laubreinbestand		-
		755 Pappel + sonstige Nadel- / Laubreinbestand		-
		759 sonstiger Laubholzbestand	nicht differenziert/nicht erkannt	-
	76 Nadelmischwald	761 Fichte + sonstige Nadel- / Laubreinbestand		-
	77 Feuchtwald	772 Auwald	räumliche Nähe zu Flüssen und Bächen, keine Möglichkeit der Unterscheidung mit gewässerbegleitende Gehölze	-
	78 Waldrandbereiche/Vorwälder	783 Vorwaldstadium	30% Deckung	-
8 Acker	79 Erstaufforstung			o
	81 Acker	811 Ackerbrache		o
	82 Sonderkulturen	821 Erwerbsgartenbau		-
9 Siedlung, Infrastruktur, Grünflächen	91 Wohngebiet	911 städtisch geprägt		o
		912 ländlich geprägt		o
		913 Einzelanwesen, Langasthof		o
	92 Mischgebiet	921 städtisches Mischgebiet		o
		922 dörfliches Mischgebiet		o
	93 Gewerbegebiet	931 Industrie- und Gewerbegebiet		o
		933 landwirtschaftlicher Betriebsstandort	Funktion nicht erkennbar	-
		934 technische Infrastruktur, Ver- und Entsorgung	Funktion nicht erkennbar	-
	94 Grün- und Freiflächen	941 kleiner Parkanlage	im Kontext einer Siedlung	o
		942 Sport- und Freizeitanlage	nur Sportplätze	o
		944 Kleingartenanlage		o
		948 Garten, Gartenbranche, Grabeland		o
	95 Verkehrsflächen	952 Platz		-
		953 Bahnanlage		o
	96 anthropogen genutzte Standorte	962 Lagerflächen	Funktion nicht erkennbar	o
		963 Aufschüttung und Altablagerung		o

\*VB = Visuelle Erkennbarkeit in RapidEye



Tabelle A 2: BLNTK-Codes der Biotoptypen- und Landnutzungsklassen für das Land Mecklenburg-Vorpommern.

OG	HG	Bestand/Biotoptyp	Merkmale aus BNTK /Problem	VB
B00 Wald, Gehölz	B10 Wald	B11 Laubwald		o
		B12 Laubwald, gemischt	(< 10 % Nadelbäume)	o
		B13 Laubmischwald	(Verhältnis Laub- zu Nadelbäumen 90/10 - 70/30)	o
		B14 Mischwald	(Verhältnis Laub- zu Nadelbäumen 50/50)	o
		B15 Nadelmischwald	(Verhältnis Nadel- zu Laubbäumen 90/10 - 70/30)	o
		B16 Nadelwald		o
		B17 Waldrand	Funktion	-
		B18 Kahlschlag	Funktion	-
		B19 Lichtung/Schneise	Funktion	-
	B20 Baumgruppe, Hecke, Gebüsch	B21 Feldgehölz	(0,5 - 4 ha)	+
		B22 Baumgruppe	(< 0,5 ha)	+
		B23 Baumreihe		+
		B24 Allee		o
		B25 Dominanter Einzelbaum		+
		B26 Hecke		o
		B27 Gebüsch, Strauchgruppe		o
L00 Landwirtschaftliche Nutzfläche	L10 Grünland	L11 Feuchtgrünland	aus CIR nicht erkennbar welches Grünland	o
		L12 frisches Grünland		o
		L14 Trockengrünland		o
		L15 Salzgrasland		o
	L20 Acker, Erwerbsgartenbau	L21 Acker		+
		L22 Erwerbsgartenbau		-
R00 Abgrabung und Aufschüttung	R10 Rohstoffgewinnung	-		-
	R20 Aufschüttung	R23 Spülfeld		-
S00 Siedlung, Infrastruktur, Landschaftsbauten	S10 Wohngebiet	S12 Einzelbebauung		o
	S20 Mischgebiet	S21 städtisches Mischgebiet		o
		S22 dörfliches Mischgebiet		o
		S23 Einzelgehöft		o
	S30 Produktionsanlage	S31 Gewerbe- und Industriegebiet		o
	S40 Freifläche	S41 Park		o
		S44 Sportanlage		o

		S47 Kleingartenanlage, Ferienhäuser		o
	S50 Verkehrsflächen	S53 Wirtschaftsweg, befestigt		-
		S54 Straße		o
		S56 Bahn/Gleisanlage		o
		S58 Hafenanlage		o
	S60 Wasserbauwerk	S61 Deich, Damm		o
	S70 Ver- und Entsorgungsanlage	S72 Klärbecken/-anlage		o
T00 Trocken-/Magerrasen/Felsflur	T10 Heide	T11 Zwergstrauchheide		o
	T20 Trockenrasen	T21 Silikattrockenrasen		o
	T30 Felsflur		nicht vorhanden	-
W00 Gewässer, Moor und Ufer (exkl. bewaldeter Moorstandorte)	W10 Fließgewässer	W12 Bach < 3 m		-
		W13 Graben < 3 m		o
		W14 Fluß > 3 m		o
		W15 Kanal > 3 m		o
	W20 Stehendes Kleingewässer	W22 permanentes Kleingewässer	< 1 ha	o
	W30 Stehendes Gewässer	W32 See	> 1 ha	+
	W40 Moor und Sumpf	W41 Niedermoor		o
		W42 Hoch- und Übergangsmoor		o
		W43 Sumpf		o
	W50 Ostsee			+
	W60 Bodden (Bucht)			o
	W70 Küstenbiotope	W72 Strand		+
		W75 Weißdüne		o

\*VB = Visuelle Erkennbarkeit in RapidEye




Abbildung A 2: F-Maß (y-Achse) je Merkmal (x-Achse) für die Klassen der Untergruppe.




Abbildung A 3: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl (Unterklassen der Baumvegetation).




Abbildung A 4: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern (Unterklassen der Baumvegetation).




Abbildung A 5: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl (Unterklassen des Grünlandes).




Abbildung A 6: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern (Unterklassen des Grünlandes).






Abbildung A 7: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme immer eines der sortierten Merkmale bis hin zur maximalen Merkmalsanzahl (Unterklassen der Siedlung und Infrastruktur).




Abbildung A 8: F-Maß (y-Achse) der RF-Klassifikation unter Hinzunahme der Merkmale die die Klassifikationsgenauigkeit verbessern (Unterklassen der Siedlung und Infrastruktur).

Tabelle A 3: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Entwicklungsgebiet Rostock.

Merkmal	Klasse
NDSM	B00
20.07.10 (RE) Textur (Mittelwert) Band 4	B00
20.07.10 (RE) GRVI	B00
20.07.10 (RE) Textur (Mittelwert) Band2	B00
09.07.10 (RE) NDGI	B00
NDSM	L00
09.07.10 (RE) Textur (Varianz) Band 5	L00
20.08.09 (RE) IC (Band 2)	L00
06.06.10 (RE) Textur (Dissimilarity) Band 5	L00
20.07.10 (RE) Textur (Varianz) Band 5	L00
20.08.09 (RE) PCA (Band 1)	L00
09.07.10 (RE) Band 1	L00
Objektfläche	L00
20.07.10 (RE) Textur (Second Moment) Band 5	L00
Dichte	L00
27.04.09 (TSX-VV) Textur (Dissimilarity) Band 1	L00
09.07.10 (RE) Textur (Homogeneity) Band 2	L00
06.06.10 (RE) PCA Band 2	S00
09.07.10 (RE) Textur (Mittelwert) Band 1	S00
06.06.10 (RE) Band 3	S00
20.07.10 (RE) Textur (Mittelwert) Band 1	S00
09.07.10 (RE) Textur (Varianz) Band 3	S00
Objektlänge	S00
20.08.09 (RE) Band 5	W00
09.07.10 (RE) Band 5	W00
09.07.10 (RE) Textur (Mittelwert) Band5	W00
09.07.10 (RE) MNF Band 3	W00
20.07.10 (RE) MNF Band 2	W00
Kompaktheit	W00
20.07.10 (RE) Textur (Varianz) Band 4	W00
Objektlänge	W00
09.07.10 (RE) Textur (Mittelwert) Band3	W00
06.06.10 (RE) MNF Band 5	B11
06.06.10 (RE) IC (Band 2)	B11
09.07.10 (RE) MNF (Band 4)	B11
09.07.10 (RE) IC (Band 1)	B11
20.08.09 (RE) PCA (Band 4)	B11
06.06.10 (RE) MNF (Band 3)	B16
06.06.10 (RE) IC (Band 2)	B16
09.07.10 (RE) MNF (Band 5)	L10
20.08.09 (RE) Textur (Korrelation) Band 5	L10
09.07.10 (RE) Textur (Second Moment) Band 2	L10
20.07.10 (RE) Textur (Kontrast) Band 2	L10
20.08.09 (RE) Textur (Varianz) Band 5	L20

20.08.09 (RE) Band 2	L20
20.08.09 (RE) MNF_Band 1	L20
06.06.10 (RE) IC Band 1	L20
06.06.10 (RE) Textur (Mittelwert) Band 4	L20
20.07.10 (RE) Textur (Dissimilarity) Band 5	W40
20.08.09 (RE) Textur (Mittelwert) Band 4	W40
20.08.09 (RE) Band 4	W40
20.07.10 (RE) Textur (Mittelwert) Band 4	W40
06.06.10 (RE) PCA (Band 1)	W40
20.08.09 (RE) Band 2	W40
Dichte	W40
20.07.10 (RE) Band 1	W40
20.07.10 (RE) Textur (Varianz)_Band 1	W40
09.07.10 (RE) Textur (Dissimilarity)_Band 1	W40
06.06.10 (RE) Textur (Kontrast) Band 2	R00
20.07.10 (RE) IC (Band 2)	S10
Objektlänge	S10
09.07.10Textur (Second Moment) Band 3	S10
06.06.10 (RE) Textur (Entropy) Band 5	L11
06.06.10 (RE) PCA (Band 3)	L11
09.07.10 (RE) MNF (Band 4)	L11
06.06.10 (RE) Textur (Homogeneity) Band 4	L11
09.07.10 (RE) NDGI	L11
20.08.09 (RE) PCA Band 5	L11
06.06.10 (RE) Textur (Mittelwert) Band 4	L12
06.06.10 (RE) Band 4	L12
20.08.09 (RE) MNF_Band 1	L12
09.07.10 (RE) IC (Band 3)	L12
20.08.09 (RE) Textur (Mittelwert) Band 4	L12
20.07.10 (RE) MNF (Band 1)	L12
09.07.10 (RE) Textur (Second Moment) Band 5	L12
Dichte	L12
06.06.10 (RE) GRVI	L12
20.08.09 (RE) PCA (Band 5)	L12
Fläche	L12
Objektdicke	L14
20.07.10 (RE) IC (Band 2)	L14
06.06.10 (RE) GRVI	L14
20.08.09 (RE) IC (Band 5)	L14
20.08.09 (RE) Textur (Dissimilarity)_Band 1	L15
20.08.09 (RE) Band 5	L15
09.07.10 (RE) Band 5	L15
20.07.10 (RE) IC (Band 3)	L15
20.08.09 (RE) Band 2	L15
06.06.10 (RE) SAVI	L15
06.06.10 (RE) Band 5	W40
20.07.10 (RE) Textur (Mittelwert) Band 4	W40

09.07.10 (RE) Textur (Kontrast) Band 4	W40
20.08.09 (RE) NDGI	W40
Objektbreite	W40

Tabelle A 4: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Übertragbarkeitsgebiet Groitzsch.

Merkmal	Klasse
03.07.10 (RE) Textur (Homogeneity) Band 5	L11
03.07.10 (RE) Textur (Homogeneity) Band 4	L11
27.097.09 (RE) Band 4	L11
05.06.10 (RE) Band 4	L11
05.06.10 (RE) Textur (Kontrast) Band 2	L11
05.06.10 (RE) IC (Band 1)	L14
19.08.09 (RE) Textur (Second Moment) Band 4	W40
03.07.10 (RE) Textur (Varianz) Band 5	W40
19.08.09 (RE) Textur (Kontrast) Band 4	W40
03.07.10 (RE) Textur (Kontrast) Band 4	W40
05.06.10 (RE) Textur (Korrelation) Band 4	W40
05.06.10 (RE) Textur (Dissimilarity) Band 2	W40
Objekthelligkeit	W40
03.07.10 (RE) PCA (Band 1)	R00
05.06.10 (RE) MNF Band 3	R00
05.06.10 (RE) PCA Band 2	R00
Objektlänge	S10
19.08.09 (RE) IC Band 4	S10
03.07.10 (RE) Textur (Entropy) Band 4	S10
03.07.10 (RE) MNF Band 3	S10
27.097.09 (RE) Band 2	L10
19.08.09 (RE) Textur (Mittelwert) Band 2	L10
19.08.09 (RE) Band 4	L10
19.08.09 (RE) Band 2	L10
19.08.09 (RE) NDGI	L10
05.06.10 (RE) Textur (Kontrast) Band 5	L10
09.06.10 (TSX VV) Textur (Mittelwert)	L10
19.08.09 (RE) MNF Band 1	L10
19.08.09 (RE) Textur (Korrelation) Band 5	L10
09.06.10 (TSX VV)	L10
19.08.09 (RE) NDVI	L20
19.08.09 (RE) Band 2	L20
19.08.09 (RE) IC Band 1	L20
19.08.09 (RE) GRVI	L20
03.07.10 (RE) MNF Band 4	L20
19.08.09 (RE) Textur (Second Moment) Band 4	W40
03.07.10 (RE) Textur (Varianz) Band 5	W40
19.08.09 (RE) Textur (Kontrast) Band 4	W40
19.08.09 (RE) Textur (Varianz) Band 4	W40
03.07.10 (RE) Textur (Dissimilarity) Band 5	W40

03.07.10 (RE) Textur (Kontrast) Band 4	W40
05.06.10 (RE) Textur (Korrelation) Band 4	W40
05.06.10 (RE) Textur (Entropy) Band 1	B11
05.06.10 (RE) PCA (Band 1)	B11
05.06.10 (RE) PCA (Band 1)	B16
03.07.10 (RE) Textur (Mittelwert) Band 2	B00
03.07.10 (RE) Band 2	B00
19.08.09 (RE) Textur (Mittelwert) Band 2	B00
19.08.09 (RE) Band 1	B00
19.08.09 (RE) Textur (Second Moment) Band 5	B00
27.097.09 (RE) Band 2	B00
03.07.10 (RE) Band 1	B00
19.08.09 (RE) GRVI	B00
NDSM	L00
05.06.10 (RE) Textur (Dissimilarity) Band 4	L00
05.06.10 (RE) Textur (Varianz) Band 4	L00
27.097.09 (RE) Band 2	L00
03.07.10 (RE) Textur (Varianz) Band 4	L00
Objekthelligkeit	L00
Fläche	L00
03.07.10 (RE) Textur (Kontrast) Band 1	L00
05.06.10 (RE) Textur (Entropy) Band 3	S00
05.06.10 (RE) Textur (Kontrast) Band 1	S00
05.06.10 (RE) Textur (Entropy) Band 1	S00
05.06.10 (RE) SAVI	S00
03.07.10 (RE) GEMI	S00
05.06.10 (RE) Band 4	W00
03.07.10 (RE) IC Band 4	W00

Tabelle A 5: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Übertragbarkeitsgebiet Rostock.

Merkmal	Klasse
NDSM	B00
30.12.17 (S1 VH) Textur (Mittelwert)	B00
30.04.17 (S2) SAVI	B00
30.11.17 (S1 VH)	B00
30.08.17 (S2) GRVI	B00
27.05.17 (S2) Band 10	B00
15.02.17 (S1 VH) Textur (Mittelwert)	L00
30.08.17 (S2) MNF Band 2	L00
27.01.17 (S2) MNF Band 6	L00
27.05.17 (S2) Textur (Mittelwert) Band 1	L00
27.01.17 (S2) IC Band 5	L00
09.07.17 (S2) Band 1	L00
30.04.17 (S2) Textur (Mittelwert) Band 7	L00
27.05.17 (S2) Textur (Second Moment) Band 11	L00
01.04.17 (S1 VV) Textur (Mittelwert)	L00

27.02.17 (S1 VH)	L00
28.03.17 (S2) MNF Band 3	L00
31.07.17 (S2) Textur (Entropy) Band 13	L00
18.12.17 (S2) Textur (Entropy) Band 2	S00
27.05.17 (S2) Band 2	S00
30.08.17 (S2) Textur (Korrelation) Band 2	S00
18.12.17 (S2) Textur (Second Moment) Band 2	S00
27.05.17 (S2) Textur (Entropy) Band 1	S00
18.12.17 (S2) Textur (Homogeneity) Band 2	S00
27.05.17 (S2) Band 1	S00
27.05.17 (S2) Textur (Varianz) Band 1	S00
30.04.17 (S2) Textur (Homogeneity) Band 1	S00
18.12.17 (S2) Textur (Dissimilarity) Band 2	S00
30.04.17 (S2) Textur (Korrelation) Band 1	S00
18.12.17 (S2) MNF Band 4	S00
27.05.17 (S2) Textur (Mittelwert) Band 13	S00
30.08.17 (S2) Textur (Mittelwert) Band 4	S00
28.03.17 (S2) Textur (Entropy) Band 13	S00
27.05.17 (S2) Band 8	W00
30.08.17 (S2) GNDVI	W00
30.04.17 (S2) Band 6	W00
28.03.17 (S2) DVI	W00
27.05.17 (S2) PCA Band 5	W00
27.01.17 (S2) Band 9	W00
28.03.17 (S2) PCA Band 2	W00
28.03.17 (S2) PCA Band 5	W00
31.07.17 (S2) MNF Band 9	W00
16.10.17 (S1 VV) Textur (Varianz)	W00
30.08.17 (S2) Textur (Mittelwert) Band 9	B11
30.08.17 (S2) Textur (Mittelwert) Band 10	B11
30.08.17 (S2) PCA Band 8	B11
30.04.17 (S2) Textur (Homogeneity) Band 8	B11
30.08.17 (S2) MNF Band 5	B16
30.08.17 (S2) MNF Band 1	B16
30.08.17 (S2) IC Band 9	B16
27.05.17 (S2) IC Band 1	B16
27.05.17 (S2) MNF Band 8	B16
30.08.17 (S2) IC Band 2	B16
31.01.17 (S1 VH)	B16
28.03.17 (S2) IC Band 12	B16
30.04.17 (S2) Textur (Varianz) Band 6	B16
27.05.17 (S2) Band 3	L10
31.07.17 (S2) GRVI	L10
31.07.17 MNF Band 2	L10
18.12.17 (S2) Textur (Entropy) Band 1	L10
30.08.17 (S2) Band 3	L10
Objektlänge	L10



30.08.17 (S2) Textur (Mittelwert) Band 12	L10
30.04.17 (S2) GNDVI	L10
09.07.17 (S2) MNF Band 11	L10
09.07.17 (S2) Textur (Mittelwert) Band 2	L10
27.05.17 (S2) Textur (Mittelwert) Band 12	L20
27.05.17 (S2) Band 2	L20
27.05.17 (S2) MNF Band 2	L20
30.04.17 (S2) MNF Band 13	L20
28.03.17 (S2) GRVI	L20
30.04.17 (S2) Textur (Mittelwert) Band 5	W40
28.03.17 (S2) Band 8	W40
27.05.17 (S2) Textur (Mittelwert) Band 10	W40
28.03.17 (S2) Textur (Mittelwert) Band 12	W40
27.05.17 (S2) Textur (Mittelwert) Band 9	W40
27.02.17 (S1 VV)	R00
27.05.17 (S2) Textur (Varianz) Band 13	S10
30.04.17 (S2) IC Band 5	S10
09.07.17 (S2) SAVI	L11
09.07.17 (S2) IC Band 6	L11
18.12.17 (S2) Band 2	L11
27.01.17 (S2) Textur (Dissimilarity) Band 9	L11
27.01.17 (S2) Textur (Second Moment) Band 9	L11
09.07.17 (S2) IC Band 2	L11
15.07.17 (S1 VH) Textur (Entropy)	L11
16.12.17 (S1 VV) Textur (Dissimilarity)	L11
09.07.17 (S2) Textur (Varianz) Band 2	L11
18.12.17 (S2) Textur (Varianz) Band 12	L11
27.01.17 (S2) SAVI	L12
27.01.17 (S2) EVI	L12
28.03.17 (S2) GEMI	L12
27.01.17 (S2) DVI	L12
30.04.17 (S2) Textur (Mittelwert) Band 10	L12
28.03.17 (S2) Band 6	L12
31.07.17 (S2) PCA Band 4	L12
09.07.17 (S2) Band 12	L12
27.05.17 (S2) Textur (Homogeneity) Band 11	L12
27.01.17 (S2) PCA Band 7	L14
15.03.17 (S1 VH) Textur (Mittelwert)	L14
15.03.17 (S1 VH)	L14
31.07.17 Textur (Entropy) Band 10	L14
28.03.17 (S2) PCA Band 6	L14
09.07.17 (S2) Band 13	L15
27.01.17 (S2) Band 7	L15
Objektbreite	L15
30.04.17 (S2) MNF Band 1	L15
18.12.17 (S2) Textur (Mittelwert) Band 9	L15
30.04.17 (S2) Textur (Mittelwert) Band 5	W40

30.04.17 (S2) Band 5	W40
28.03.17 (S2) Band 8	W40
28.03.17 (S2) Textur (Mittelwert) Band 12	W40
30.04.17 (S2) IC Band 12	W40
30.08.17 (S2) Textur (Varianz) Band 13	W40

Tabelle A 6: Liste der Merkmale für die Klassen basierend auf weichen Merkmale für das Übertragbarkeitsgebiet Rostock inklusiver multi-temporaler Merkmale.

Merkmal	Klasse
15.02.17 (S1 VH)	B00
S1 (VV) multi-temporaler Mittelwert	B00
28.03.17 (S2) DVI	B00
S1 (VV) multi-temporale Textur (Mittelwert)	B00
30.12.17 (S1 VH)	B00
30.11.17 (S1 VH)	B00
27.01.17 (S2) MNF Band 6	L00
NDSM	L00
30.08.17 (S2) MNF Band 2	L00
30.04.17 (S2) Textur (Mittelwert) Band 7	L00
30.04.17 (S2) Textur (Mittelwert) Band 8	L00
31.07.17 (S2) Band 8	L00
09.07.17 (S2) PCA Band 1	L00
31.07.17 (S2) MNF Band 4	L00
27.05.17 (S2) Textur (Kontrast) Band 11	L00
27.05.17 (S2) Band 1	L00
S2 (NDVI) multi-temporale Varianz	L00
S2 (Textur) multi-temporaler Mittelwert	S00
27.05.17 (S2) Band 2	S00
S2 (Textur) multi-temporaler Mittelwert	S00
30.08.17 (S2) Textur (Korrelation) Band 2	S00
30.04.17 (S2) Textur (Homogeneity) Band 1	S00
27.05.17 (S2) Textur (Mittelwert) Band 2	S00
30.08.17 (S2) Textur (Mittelwert) Band 1	S00
28.03.17 (S2) Textur (Homogeneity) Band 2	S00
27.05.17 (S2) GNDVI	S00
31.07.17 (S2) Textur (Mittelwert) Band 2	S00
30.04.17 (S2) PCA Band 3	S00
S2 (Textur) multi-temporale Standardabweichung	S00
01.01.17 (S1 VV) Textur (Kontrast)	S00
27.05.17 (S2) MNF Band 6	W00
27.05.17 (S2) PCA Band 7	W00
28.03.17 (S2) MNF Band 7	W00
09.07.17 (S2) PCA Band 1	W00
27.05.17 (S2) IC Band 2	W00
31.01.17 (S1 VH)	W00
28.03.17 (S2) Textur (Mittelwert) Band 7	W00
30.04.17 (S2) IC Band 6	W00

S1 (VV) multi-temporaler Mittelwert	W00
16.05.17 (S1 VH)	W00
30.08.17 (S2) Textur (Mittelwert) Band 9	B11
30.08.17 (S2) Textur (Mittelwert) Band 10	B11
30.08.17 (S2) PCA Band 8	B11
28.03.17 (S2) IC Band 3	B11
30.08.17 (S2) MNF Band 5	B16
30.08.17 (S2) MNF Band 1	B16
30.08.17 (S2) IC Band 9	B16
27.05.17 (S2) IC Band 1	B16
S2 (GRVI) multi-temporale Varianz	B16
27.05.17 (S2) MNF Band 8	B16
27.01.17 (S2) MNF Band 10	B16
S2 (Textur) multi-temporale Varianz	B16
27.05.17 (S2) Band 3	L10
31.07.17 (S2) GRVI	L10
31.07.17 (S2) MNF Band 2	L10
27.05.17 (S2) MNF Band 2	L10
30.08.17 (S2) Band 4	L10
30.09.17 (S1 VH) Textur (Mittelwert)	L10
28.03.17 (S2) Textur (Mittelwert) Band 13	L10
30.04.17 (S2) Band 5	L10
S2 (Textur) multi-temporale Standardabweichung	L10
09.07.17 (S2) Textur (Kontrast) Band 12	L10
27.05.17 (S2) Textur (Mittelwert) Band 12	L20
27.05.17 (S2) Band 2	L20
27.05.17 (S2) Band 4	L20
27.01.17 (S2) PCA Band 2	L20
31.07.17 (S2) PCA Band 6	L20
27.01.17 (S2) MNF Band 8	L20
30.04.17 (S2) Textur (Mittelwert) Band 5	W40
28.03.17 (S2) Band 8	W40
S2 (Band 12) multi-temporaler Mittelwert	W40
28.03.17 (S2) Textur (Mittelwert) Band 12	W40
S2 (Textur) multi-temporaler Mittelwert	W40
S2 (Textur) multi-temporaler Mittelwert	R00
S2 (Textur) multi-temporale Varianz	R00
30.04.17 (S2) Textur (Dissimilarity) Band 13	S10
16.10.17 (S1 VV) Textur (Mittelwert)	S10
31.07.17 (S2) Textur (Homogeneity) Band 1	S10
09.07.17 (S2) IC Band 6	L11
09.07.17 (S2) SAVI	L11
09.07.17 (S2) NDVI	L11
18.12.17 (S2) (S2) Band 2	L11
31.07.17 (S2) MNF Band 12	L11
27.05.17 (S2) Textur (Homogeneity) Band 8	L11
S2 (Textur) multi-temporaler Mittelwert	L11

27.05.17 (S2) Textur (Second Moment) Band 7	L11
30.08.17 (S2) MNF Band 4	L11
30.09.17 (S1 VH) Textur (Kontrast)	L11
31.07.17 (S2) GNDVI	L11
27.01.17 (S2) SAVI	L12
27.01.17 (S2) EVI	L12
27.01.17 (S2) DVI	L12
28.03.17 (S2) GEMI	L12
28.03.17 (S2) Textur (Mittelwert) Band 10	L12
28.03.17 (S2) Band 7	L12
31.07.17 (S2) Band 10	L12
S2 (Textur) multi-temporaler Mittelwert	L12
S2 (GRVI) multi-temporaler Mittelwert	L12
30.04.17 (S2) Textur (Mittelwert) Band 3	L12
18.12.17 (S2) (S2) Textur (Mittelwert) Band 12	L12
30.08.17 (S2) Textur (Mittelwert) Band 7	L12
27.05.17 (S2) Textur (Mittelwert) Band 12	L12
30.04.17 (S2) Textur (Varianz) Band 7	L12
27.01.17 (S2) PCA Band 7	L14
S1 (VV) multi-temporale 5 % Perzentile	L14
15.03.17 (S1 VH) Textur (Mittelwert)	L14
28.03.17 (S2) PCA Band 6	L14
S2 (Band 8) multi-temporaler Mittelwert	L15
09.07.17 (S2) Band 13	L15
28.03.17 (S2) Band 11	L15
30.04.17 (S2) Textur (Mittelwert) Band 5	W40
30.04.17 (S2) IC Band 1	W40
28.03.17 (S2) Textur (Mittelwert) Band 12	W40
14.08.17 (S1 VV)	W40
18.12.17 (S2) MNF Band 1	W40

## **Selbstständigkeitserklärung**

Ich erkläre,

dass mir die geltende Promotionsordnung der Fakultät bekannt ist;

dass ich die Dissertation selbst angefertigt, keine Textabschnitte eines Dritten oder eigener Prüfungsarbeiten ohne Kennzeichnung übernommen und alle von mir benutzten Hilfsmittel, persönlichen Mitteilungen und Quellen in meiner Arbeit angegeben habe;

dass die Hilfe einer kommerziellen Promotionsvermittlung nicht in Anspruch genommen wurde und dass Dritte weder unmittelbar noch mittelbar geldwerte Leistungen von mir für Arbeiten erhalten haben, die in Zusammenhang mit dem Inhalt der vorgelegten Dissertation stehen;

dass ich die Dissertation noch nicht als Prüfungsarbeit für eine staatliche oder andere wissenschaftliche Prüfung eingereicht haben;

dass ich nicht die gleiche, eine in wesentlichen Teilen ähnliche oder eine andere Abhandlung bei einer anderen Hochschule als Dissertation eingereicht habe.

Alling, den 01.12.2018